



ESCUELA TÉCNICA SUPERIOR DE INGENIERÍA Y SISTEMAS DE TELECOMUNICACIÓN

PROYECTO FIN DE GRADO

TÍTULO: Clasificación de Imágenes Dermatoscópicas

AUTOR: Álvaro Martínez Martínez

TITULACIÓN: Grado en Ingeniería de Sonido e Imagen

TUTOR: Danilo Simón Zorita

DEPARTAMENTO: DIAC

VºBº

Miembros del Tribunal Calificador:

PRESIDENTE: Cristina Bonis Téllez

VOCAL: Danilo Simón Zorita

SECRETARIO: Alfonso Martín Marcos

Fecha de lectura:

Calificación:

El Secretario,

Resumen

Este proyecto presenta un software para el análisis de imágenes dermatoscópicas correspondiente a lesiones melanocíticas, con el fin de clasificarlas entre lesiones benignas y melanoma.

El sistema realiza una segmentación automática de la lesión y la procesa en varias etapas, extrayendo características de relevancia diagnóstica: asimetría, colores, irregularidad del borde, y la presencia de estructuras como redes pigmentadas atípicas o velo azul-blanquecino. Proporciona además una herramienta para el etiquetado manual de estructuras adicionales.

La clasificación automática de las lesiones se realiza en base a los métodos de diagnóstico más comúnmente utilizados: las reglas ABCD, Menzies, 7-point checklist, CASH y CHAOS & CLUES.

El sistema de clasificación se evalúa sobre una base de datos de imágenes dermatoscópicas, y se realiza una comparativa de los resultados obtenidos por cada método de diagnóstico.

Abstract

This project presents a software for the analysis of dermoscopic images of melanocytic lesions, and their classification into benign lesions and melanoma.

The system performs automatic segmentation of the lesion and goes through several stages of extraction of certain characteristics relevant to the diagnosis, such as asymmetry, border irregularity, or presence of structures like atypical pigmented network or blue-whitish veil.

Automatic classification of the lesions is accomplished by means of the most commonly used diagnostic methods, such as ABCD and Menzies's rules, the 7-point checklist, CASH, and CHAOS & CLUES.

The classification system is evaluated by using a dermoscopic image database, and a comparison of the results yielded by the different diagnostic methods is performed.

Índice de contenidos

Resumen	1
Abstract.....	2
Lista de acrónimos	5
Índice de figuras	6
Índice de tablas.....	8
Introducción.....	9
I. Marco contextual.....	11
1. El melanoma	11
2. Algoritmos de clasificación de lesiones	16
2.1. Regla ABCD.....	16
2.2. Método de Menzies.....	17
2.3. Regla de los 7 puntos	18
2.4. CASH.....	18
2.5. CHAOS & CLUES	19
3. Estado del arte de la dermatoscopia	22
4. Técnicas de procesado de imagen.....	25
4.1. Archivos de imagen y sistemas de color	25
4.2. Propiedades de la imagen.....	26
4.3. Segmentación de imagen.....	27
4.4. Operaciones morfológicas	31
5. Técnicas de clasificación.....	32
II. Antecedentes	35
III. Descripción de la solución propuesta	37
6. Base de datos	37
7. Interfaz de usuario.....	38
8. Segmentación de las lesiones.....	39
9. Extracción de características.....	45
9.1. Asimetría	45
9.2. Bordes	47
9.3. Colores	50
9.4. Diferencias estructurales	51
9.4.1. Retículo pigmentado.....	51

Tabla de contenidos

9.5. Velo azul-blanquecino.....	56
9.5.1. Manchas y glóbulos, proyecciones radiales (<i>streaks</i>) y zonas de regresión.....	57
10. Clasificación automática de las lesiones	59
11. Evaluación de los resultados	62
IV. Resultados, conclusiones y futuras líneas de investigación	63
12. Resultados.....	63
13. Conclusiones	65
14. Mejoras y futuras líneas de investigación	67
Anexo I – Referencia de funciones implementadas	69
Anexo II – Descripción de los componentes de la interfaz de usuario	70
Referencias	73

Lista de acrónimos

FN:	<i>False Negative</i> , muestra positiva clasificada como negativa.
FP:	<i>False Positive</i> , muestra negativa clasificada como positiva.
GUI:	<i>Graphical User Interface</i> , interfaz gráfica de usuario.
ROI:	<i>Region Of Interest</i> , región de interés de una cierta característica
TN:	<i>True Negative</i> , muestra negativa clasificada como negativa.
TP:	<i>True Positive</i> , muestra positiva clasificada como positiva.
UV:	Ultravioleta. Tipos de radiación ultravioleta: UVA, UVB, UVC

Figura 1-1 - Estructura de la piel.....	12
Figura 2-1 - Colores en CHAOS & CLUES	19
Figura 2-2 - Algoritmo CHAOS & CLUES	20
Figura 3-1 - Dermatoscopio manual HEINE.....	22
Figura 3-2 - Dermatoscopio manual DERMLITE	22
Figura 3-3 – FotoFinder	23
Figura 3-4 – MoleMax.....	23
Figura 3-5 - App FotoSkin.....	23
Figura 3-6 - MoleScope	24
Figura 4-1 - Rueda de color HSV.....	25
Figura 4-2 - Máscara detección de puntos.....	27
Figura 4-3 - Máscara detección de líneas horizontales	28
Figura 6-1 - Imagen RGB de una lesión	38
Figura 6-2 - Segmentación manual de la lesión.....	38
Figura 6-3 - ROI del color 4	38
Figura 6-4 - ROI del color 5	38
Figura 7-1 - Interfaz Gráfica de Usuario.....	39
Figura 8-1 - Esquema segmentación	41
Figura 8-2 - Comparativa segmentación automática/manual.....	42
Figura 8-3 - Problemas de segmentación – zonas de regresión.....	42
Figura 8-4 - Segmentación por umbral múltiple	43
Figura 8-5 - Segmentación por clustering (k-medias)	43
Figura 8-6 - Problemas de segmentación - pelos (1).....	43
Figura 9-1 - Estudio de asimetría.....	46
Figura 9-2 - Árbol de decisión – Asimetría	47
Figura 9-3 – Ejemplos estudio del borde	48
Figura 9-4 - Análisis del borde	49
Figura 9-5 - Ejemplo de melanoma con retículo pigmentado.....	51
Figura 9-6 - Extracción del retículo pigmentado	52
Figura 9-7 - Post-procesado del retículo pigmentado	53
Figura 9-8 - Segmentación de las zonas con patrón reticular.....	53
Figura 9-9 - Esquema detección de red pigmentada	55

Figura 9-10 - Diagrama de bloques "Blue Veil"	56
Figura 9-11 - Detección de "Blue Veil"	57
Figura 9-12 - Herramienta de etiquetado de estructuras (imagen con <i>dots</i> y áreas de regresión)	58
Figura 9-13 - Herramienta de etiquetado de estructuras (imagen con <i>streaks</i>).....	58
Figura 10-1 – Implementación método ABCD	60
Figura 10-2 - Implementación regla de Menzies.....	60
Figura 10-3 - Implementación método 7-point checklist	60
Figura 10-4 - Implementación regla CHAOS & CLUES	61

Índice de tablas

Tabla 2-1 - Puntuación regla ABCD.....	17
Tabla 2-2 - Características método de Menzies	17
Tabla 2-3 - Puntuación <i>7-point Checklist</i>	18
Tabla 2-4 - Puntuación CASH.....	18
Tabla 2-5 – Valores detección de velo azul-blانquecino.....	57
Tabla 11-1 – Tabla para evaluar el diagnóstico	62
Tabla 12-1 – Resultados diagnóstico automático	63
Tabla 12-2 – Resultados diagnóstico automático utilizando características de la base de datos.....	63

Introducción

Los avances tecnológicos de las últimas décadas han proporcionado numerosas y potentes herramientas al mundo de la salud que facilitan el trabajo de los profesionales sanitarios y permiten nuevos procedimientos de diagnóstico y tratamiento antes inviables.

El desarrollo del campo de la bioingeniería así como de otras disciplinas estrechamente relacionadas, como la inteligencia artificial o la visión por ordenador, se encuentra en continua expansión a través de la investigación y el diseño de nuevos equipos y técnicas destinados a proporcionar mayor información sobre el funcionamiento del cuerpo humano y las patologías que afectan a su salud.

En este trabajo nos centramos concretamente en un área de la ingeniería biomédica que utiliza la imagen como fuente principal de información. Se han desarrollado equipos capaces de captar imágenes del interior del cuerpo; además, mediante el procesamiento de ésta es posible observar características fuera de las capacidades de la percepción humana. Por otro lado, mediante la implementación de técnicas de visión por ordenador e inteligencia artificial se pretende emular y mejorar las capacidades de interpretación de la visión humana y aplicarlas para procesar esa información.

Este conjunto de tecnologías ha propiciado la aparición de nuevas técnicas no invasivas de diagnóstico, que facilitan la labor del médico y reducen las molestias causadas al paciente, además de ser en muchos casos más efectivas al poner al alcance del médico mucha más información. También representan una importante herramienta de asistencia a las intervenciones quirúrgicas y el seguimiento posterior a éstas.

En este trabajo se estudian las posibilidades de este campo de la ingeniería en el contexto del análisis y diagnóstico de imágenes dermatoscópicas, con el objetivo de contribuir al diagnóstico temprano del melanoma cutáneo.

El melanoma es la forma más infrecuente de los tres tipos principales de cáncer de piel, pero también la más agresiva y la que produce más muertes. La *American Cancer Society* recoge algunas estadísticas sobre el alcance de esta enfermedad, para el año 2014 [1]; a continuación se mencionan las más importantes:

- El cáncer de piel es el más común, superando en casos al resto de tipos de cáncer juntos. El melanoma representa un 2% de los casos de cáncer de piel, pero es el responsable de la mayoría de las muertes.
- El melanoma es más común en mujeres que en hombres en edades hasta los 45 años, pero a partir de los 60 años el número de casos en hombres es más del doble que en mujeres.
- Las predicciones apuntan al diagnóstico de más de 75000 nuevos casos de melanoma en 2014 en Estados Unidos, y aproximadamente 9700 muertes debidas a esta enfermedad.

Según la World Wealth Organization [2], al año se producen entre 2 y 3 millones de nuevos casos de cáncer de piel, de los cuales aproximadamente 130.000 se corresponden a melanomas malignos.

Los estudios coinciden en señalar un aumento progresivo de los casos de melanoma a lo largo de los últimos treinta años, aunque los avances en el campo del diagnóstico y la aparición de nuevas tecnologías de análisis han logrado mantener a raya la mortalidad debida a esta enfermedad.

Estructura del proyecto:

Se ha estructurado este documento en cuatro capítulos cuyos contenidos se resumen a continuación:

I. Marco contextual

En el primer capítulo de este trabajo se realiza una introducción a las características de la piel y el melanoma cutáneo, así como los métodos de diagnóstico más comúnmente empleados y la tecnología disponible para el análisis de las lesiones. Se hace también referencia a los conceptos básicos en procesamiento digital de la señal y clasificación automática.

II. Antecedentes

En el capítulo segundo se describe el estado del arte en el procesamiento de imágenes dermatoscópicas, referenciando las principales publicaciones consultadas.

III. Descripción de la solución propuesta

En este capítulo se detalla el desarrollo de cada uno de los módulos del sistema desarrollado, que comprenden la segmentación de las imágenes, la extracción de características relevantes y su clasificación en base a los métodos de diagnóstico existentes, y el procesamiento de los resultados de cara a su evaluación.

Se describe también la base de datos de imágenes dermatoscópicas utilizada y la interfaz gráfica de usuario desarrollada para el manejo del *software*.

IV. Resultados, conclusiones y futuras líneas de investigación

Finalmente se procede a evaluar los resultados obtenidos con el fin de extraer conclusiones y se hace una relación de las posibles mejoras al sistema implementado.

Anexos

En el Anexo I se listan las principales funciones implementadas en el programa, junto con una breve descripción de su funcionamiento.

El Anexo II contiene una guía para facilitar el uso del programa.

I. Marco contextual

1. El melanoma

En primer lugar se procederá a explicar en qué consiste el melanoma y dar una visión de la necesidad de herramientas de diagnóstico potentes para reducir su incidencia en la población.

La piel

La piel es el órgano más grande del cuerpo, al que proporciona un número de funciones fundamentales [3]:

- Cubrir y proteger los órganos internos frente a heridas e infecciones, así como los efectos nocivos de la radiación solar.
- Prevenir la pérdida de agua y otros fluidos, y ayudar a regular la temperatura corporal.
- Ayudar al cuerpo en la síntesis de vitamina D, esencial para el crecimiento de los huesos.
- Proporcionar información sobre el exterior a través de sus numerosas terminaciones nerviosas, capaces de captar estímulos táctiles, térmicos y dolorosos.

La dermatoscopia describe la división de la piel en tres capas, que se detallan brevemente a continuación:

- La epidermis es la capa más externa de la piel. Es la capa más delgada, con un grosor medio de 0,1 milímetros, y está constituida fundamentalmente por dos tipos de células apiladas en capas: queratinocitos y melanocitos. Los queratinocitos se sitúan en la capa más externa y están compuestas fundamentalmente por queratina; son las células encargadas de la protección externa de la piel y se renuevan continuamente. Los melanocitos, por otra parte, se encargan de la protección contra la radiación ultravioleta y son los que confieren a la piel su pigmentación natural. Por último, en la capa más profunda de la epidermis se encuentran otro tipo de células, las de Langerhans, que forman parte del sistema inmunológico.
- La dermis se sitúa bajo la epidermis y es la capa de mayor espesor. Está compuesta principalmente por fibras de colágeno y elastina, que confieren a la piel su consistencia fuerte, flexible y elástica. Pero en esta capa también se encuentran distintos tipos de células inmunológicas, glándulas sudoríparas, vasos sanguíneos, folículos sebáceos, músculos piloerectores, y receptores sensoriales capaces de captar presión y temperatura, así como estímulos dolorosos. Un tipo de musculatura de tipo estriado se encarga de fijar la piel al músculo.
- Por último, el tejido subcutáneo o hipodermis, compuesto por tejidos adiposos y macrófagos. Se encarga de conservar la temperatura corporal, y proporciona mayor o menor flexibilidad de la piel en las distintas zonas del cuerpo. En esta capa también se encuentran vasos sanguíneos y linfáticos.

I. Marco contextual

La Figura 1-1 ilustra la distribución de las capas de la piel.




Figura 1-1 - Estructura de la piel

El melanoma cutáneo

Al igual que el resto de órganos que conforman el cuerpo humano, la piel está expuesta a la aparición de distintas enfermedades debidas a mutaciones celulares o deficiencias inmunológicas, que pueden afectar al funcionamiento del resto del organismo.

Existen tres tipos principales de cáncer de piel [4]: el carcinoma basocelular, el carcinoma de células escamosas, y melanoma maligno¹. De estos tres tipos, el melanoma es considerado el más peligroso por su capacidad de generar metástasis.

El melanoma es una enfermedad consistente en la formación de células cancerosas en los melanocitos. Hemos visto anteriormente que los melanocitos son las células situadas en la epidermis que se encargan de producir un pigmento marrón llamado melanina, que se encarga de proteger a las capas más profundas de la piel de la radiación solar.

La melanina [5] es una sustancia que se encuentra en varios lugares de la parte exterior del cuerpo: en la piel, en el pelo, en el epitelio que rodea a la retina; y también en zonas internas, como en el oído interno, en zonas profundas del cerebro. Una de sus propiedades más

¹ Aunque el melanoma cutáneo es el más frecuente, existen también el melanoma intestinal y ocular (melanoma uveal), también con capacidad de causar metástasis.

importantes es la capacidad de disipar más del 99% de la radiación solar absorbida por la piel en calor, evitando que esta energía dañe el ADN de las células.

No obstante, la concentración de melanocitos en la piel de las personas y, en consecuencia, la capacidad de producción de melanina, es variable y depende de variables étnicas y genéticas. En consecuencia, personas con menor producción de melanina son más vulnerables a la radiación solar. Un caso extremo sería el del albinismo, una condición de causa genética que provoca una ausencia congénita de melanina.

Hemos remarcado la importancia de la melanina como elemento protector frente a la radiación solar, que es la principal fuente de radiación ultravioleta (UV). Se distinguen tres tipos de radiación ultravioleta:

- Rayos UVA o de onda larga (400-320nm): son los responsables del envejecimiento de la piel y se asocian al daño a largo plazo de la piel, con la aparición de arrugas y manchas. Sin embargo también pueden producir daños en el ADN de las células de la piel, provocando mutaciones que pueden desarrollar cáncer.
- Rayos UVB o de onda media (320-280nm): son los principales causantes de las quemaduras solares y, más importante, tienen mayor capacidad de producir daño directo al ADN de las células. Ello hace que se consideren los principales desencadenantes del cáncer de piel.
- Rayos UVC o de onda corta (280-200nm): potencialmente la más peligrosa; es en gran medida absorbida por la capa de ozono, aunque un porcentaje mínimo alcanza la superficie de la tierra, pudiendo producir daños en la piel.

La capacidad de la radiación ultravioleta de alterar el ADN de las células es la que la convierte en un factor desencadenante del cáncer de piel. No obstante, la mutación de las células no origina necesariamente cáncer, como se verá a continuación.

La multiplicación anormal de los melanocitos origina acumulaciones de estas células que se conocen comúnmente como lunares o nevos. Estos se consideran tumores benignos de la piel junto con otro tipo de lesiones como son las queratosis seborreicas, los hemangiomas, los lipomas o las verrugas.

No obstante, en ocasiones la alteración del ADN de los melanocitos provoca la multiplicación descontrolada de estas células, dando lugar a nuevas generaciones de células mutadas, que se acumulan dando lugar a un tumor. Este tumor puede desarrollarse de forma local o, eventualmente, acabar diseminándose a otras partes del organismo, en un proceso conocido como metástasis, común a otros tipos de cáncer. Es por ello que se considera el melanoma como el tipo más agresivo de cáncer de piel frente a otros menos peligrosos, como el cáncer de células basales o escamosas.

Diagnóstico, pronóstico y tratamiento

Hemos hablado del peligro que representa el melanoma por su capacidad de generar metástasis. Afortunadamente, un diagnóstico temprano permite en la mayoría de los casos extirpar el tumor antes de que el cáncer se propague al organismo. El diagnóstico del melanoma se realiza en primer lugar por inspección visual, que permite a los especialistas detectar características de la lesión que puedan hacerlas sospechosas de melanoma.

I. Marco contextual

Los dermatólogos recurren a diversos métodos para evaluar las características observadas y emitir un diagnóstico preliminar, que será confirmado posteriormente mediante la biopsia de la lesión. Este modo de trabajo se ve potenciado por el uso de herramientas que permitan observar las lesiones con mayor claridad y mostrar características difíciles de detectar a simple vista. Sobre esta instrumentación y los métodos de diagnóstico hablaremos en los siguientes apartados.

Una vez detectada la presencia del tumor, existen distintos sistemas para evaluar el pronóstico del melanoma en función de su evolución.

- El sistema de Breslow, que los clasifica según el espesor del tumor.
- Los niveles de Clark [6], que puntúan el melanoma en función de la invasión del resto de tejidos:
 - Estadio 0: el melanoma se ubica en la epidermis. El tratamiento consiste generalmente en la extirpación del tumor y de un margen de 5mm de piel sana. En estos casos el índice de supervivencia es del 99%.
 - Estadio I: el melanoma tiene un grosor menor de 2mm y se encuentra en la epidermis, pudiendo llegar a la capa superior de la dermis, sin haberse diseminado a los ganglios linfáticos cercanos. El tratamiento recomendado es el mismo que en la etapa anterior, aunque en algunos casos puede ser recomendable realizar una biopsia del ganglio centinela a fin de determinar si el cáncer se ha propagado a los ganglios linfáticos cercanos, en cuyo caso se extirpan. En esta etapa la supervivencia es del 90%.
 - Estadio II: el melanoma se ha diseminado a la parte inferior de la dermis, sin llegar a afectar a la hipodermis o los ganglios linfáticos cercanos, y el tumor tiene un grosor entre 2 y 4mm. En este caso se extirpa el tumor con un margen amplio y se realiza una biopsia del ganglio centinela, extirpando en caso necesario los ganglios linfáticos de la zona. La supervivencia prevista es del 80%.
 - Estadio III: el tumor tiene un espesor superior a 4mm y, además, se da alguna de las siguientes situaciones: se ha propagado a ganglios linfáticos cercanos, se encuentra cáncer entre el tumor primario y los ganglios, o pequeños tumores en el área cercana a la lesión inicial. Esto indica que el tumor se ha diseminado a los tejidos subdérmicos, apareciendo en su caso tumores satélite. En este caso, además de la extirpación amplia del tumor y ganglios vecinos, es recomendable realizar tratamiento adyuvante mediante quimioterapia, inmunoterapia o ambas. En estos casos se supone unas posibilidades de supervivencia de 50%.
 - Estadio IV: cuando el tumor se disemina a través de los ganglios linfáticos a otros órganos alejados del tumor principal, es muy difícil localizar y detener la propagación de la enfermedad. La supervivencia del paciente se ve entonces muy comprometida (20-30%). La extirpación de los órganos afectados está sujeta a su localización o la probabilidad de causen síntomas, y en ningún caso garantiza que el tumor deje de propagarse. Los tratamientos mediante inmunoterapia ayudan a ralentizar el avance de la metástasis, pero también provocan efectos secundarios graves.

El cáncer puede presentar también recurrencia, esto es, aparecer de nuevo tras haber sido tratado. En algunos casos puede aparecer en la cercanía del tumor inicial, si éste no fue extirpado en su totalidad. Así mismo, en aquellos casos en el que no se haya detectado la propagación del melanoma a los ganglios vecinos, procediendo a su extirpación, éste puede volver a aparecer y propagarse a través de ellos.

Factores de riesgo

Hemos visto que el principal factor desencadenante del melanoma es la radiación solar ultravioleta, por lo que cualquier persona puede desarrollar esta enfermedad. No obstante, existe un conjunto de factores que hacen más vulnerables a las personas frente al melanoma.

- Tener fototipos bajos, entre I y III en la escala de Fitzpatrick [7]. Estos son los fototipos propios de personas con piel clara, que tienen menor capacidad de asimilar la radiación solar, por lo que al exponerse a la luz solar casi no se broncean y se queman con facilidad.
- Haber estado expuesto mucho al sol y/o sufrido quemaduras solares en edades tempranas.
- Tener muchos lunares en todo el cuerpo. En general los médicos coinciden en que personas con más de 100 lunares en el cuerpo deberían someterse a revisiones regulares.
- Tener lunares displásicos [8], esto es, con características atípicas que presentan cierta especificidad en el melanoma. El seguimiento de este tipo de lesiones es fundamental.
- Vivir en climas con mucho sol, en alturas elevadas o en zonas en las que los rayos solares inciden con mayor intensidad (como el ecuador).
- En general, estar expuesto durante largos períodos de tiempo a la radiación solar, debido al tipo de trabajo o actividad.
- Las camas bronceadoras emiten grandes cantidades de radiación UVA o UVB, por lo que se considera que su uso supone un aumento significativo del riesgo de desarrollar cáncer de piel.
- La reducción de la capa de ozono en determinadas zonas del globo o en épocas de año disminuye la absorción de los rayos UVC, lo que aumenta el peligro de la exposición solar.

Aunque debido al aumento de casos de melanoma en las últimas décadas ha elevado la concienciación sobre esta enfermedad, persisten aún en la sociedad muchos falsos mitos fruto de la falta de información, que ponen en peligro a las personas frente a los peligros de la radiación solar. Entre ellos podemos citar la creencia de que las personas de piel morena o que no tienen lunares son inmunes a los efectos nocivos de los rayos UV, de que las sombras o los días nublados no suponen peligro de quemaduras solares, así como el uso incorrecto de la protección solar o la elección de índices de protección solar insuficientes para personas con fototipos bajos. Por último cabe destacar que la búsqueda del bronceado por motivos estéticos lleva a muchas personas a exponerse a la radiación solar de forma excesiva, o a utilizar camas de bronceado.

I. Marco contextual

Por ello, paralelamente al desarrollo de mejores técnicas de diagnóstico y tratamiento del cáncer de piel, es necesario continuar los esfuerzos por informar y concienciar a la sociedad sobre la gravedad de este problema, a fin de reducir los casos de melanoma debidos a la exposición imprudente.

2. Algoritmos de clasificación de lesiones

Existe un conjunto de diferentes algoritmos [9] utilizados para clasificar las lesiones en dos categorías: lesiones melanocíticas benignas o melanoma maligno. En el siguiente apartado se detallan brevemente las características de cada uno de ellos.

2.1. Regla ABCD

La regla ABCD [10] es quizás uno de los métodos más conocidos y aplicados para el estudio de lesiones melanocíticas. Su nombre hace referencia a las cuatro características que son evaluadas (Asimetría, Borde, Color y Diferencias estructurales²). A partir de la observación de dichas características se asigna a la lesión una puntuación semi-cuantitativa que permite determinar con bastante precisión si se trata de un melanoma o de una lesión benigna.

Concretamente, la puntuación de cada característica se realiza de acuerdo con las siguientes consideraciones:

- Asimetría: la asimetría de la lesión se valora teniendo en cuenta considerando su color y estructura. Se sitúan dos ejes perpendiculares de forma que proporcionen la menor puntuación de asimetría, siendo esta 0 en caso de simetría respecto de ambos ejes, 1 si se encuentra asimetría respecto de un único eje, y 2 si es asimétrica respecto de ambos ejes.
- Borde: Se divide el borde de la lesión en 8 segmentos, y se añade un punto a la valoración por cada segmento en el que se observa un cambio brusco de pigmentación.
- Color: la puntuación de color es la suma de los diferentes colores encontrados en la lesión. Los colores posibles son: blanco, rojo, marrón oscuro, marrón claro, azul grisáceo y negro.
- Diferencias estructurales: se suma un punto por cada patrón estructural presente en la lesión. Las posibilidades son: red pigmentada, áreas homogéneas, manchas, glóbulos, y *streaks* (proyecciones radiales pigmentadas).

² Diferentes publicaciones relacionan “D” con el diámetro de la lesión, y no con la presencia de estructuras atípicas. Ésta es una simplificación de la regla ABCD basada en el hecho de que los melanomas suelen presentar mayor tamaño que las lesiones benignas.

La siguiente tabla describe el sistema de puntuación empleado por la regla ABCD.

Criterio	Rango de puntuación	Factor	Puntuación máxima/mínima
Asimetría	0-2	1.3	0.0-2.6
Borde	0-8	0.1	0.0-0.8
Colores	1-6	0.5	0.5-3.0
Diferencias estructurales	1-5	0.5	0.5-2.5

Tabla 2-1 - Puntuación regla ABCD

En función de la puntuación calculada para una lesión, se emite un diagnóstico basado en los siguientes rangos [10]:

$P < 4,75 \rightarrow$ Lesión benigna

$4,75 < P \leq 5,45 \rightarrow$ Lesión sospechosa

$P > 5,45 \rightarrow$ Lesión maligna

2.2. Método de Menzies

El método de Menzies tiene como objetivo simplificar el diagnóstico para observadores poco experimentados, que podrían no ser capaces de asignar las puntuaciones correctas mediante el método ABCD.

Este método se basa en la observación de la presencia de ciertas estructuras características del melanoma maligno, frente a dos características propias que no indican malignidad. Las características mencionadas se muestran en la siguiente tabla.

Características benignas	Características malignas
Patrones simétricos Color uniforme	Patrones asimétricos Más de un color Presencia de alguno de los nueve patrones: <ol style="list-style-type: none"> 1. Velo blanco-azul 2. Puntos oscuros 3. Pseudópodos 4. Distribución radial 5. Zonas sin pigmento ("cicatrices") 6. Puntos negros en la periferia 7. Colores múltiples (5-6) 8. Puntos de color azul/gris 9. Pigmento reticular

Tabla 2-2 - Características método de Menzies

I. Marco contextual

2.3. Regla de los 7 puntos

Al igual que el método de Menzies [11], este método pretende simplificar el diagnóstico a través de la identificación de ciertos patrones en la lesión. En este caso se puntúa cada característica en función de su relevancia en las lesiones malignas.

La siguiente tabla presenta las características buscadas y sus puntuaciones.

Criterio	Características	Puntaje
Mayor	Pigmento reticular atípico Patrón vascular atípico Velo azul-blanquecino	2
Menor	Líneas irregulares Pigmentación irregular Puntos irregulares Áreas de regresión	1

Tabla 2-3 - Puntuación 7-point Checklist

El diagnóstico es positivo (melanoma) en caso de que la suma de las puntuaciones de los patrones encontrados es mayor que 3.

2.4. CASH

Acrónimo referido a “Colour, Architecture, Symmetry, Homogeneity” [12]. Es otro método semi-cuantitativo que asigna puntajes a estas cuatro características y emite un diagnóstico a partir de la puntuación total. El sistema de puntuación se muestra en la siguiente tabla.

	Baja	Media	Alta
Colores: un punto por cada color presente. Siendo los colores posibles: marrón claro, marrón oscuro, negro, rojo, blanco y azul.	1-2 colores (1-2 puntos)	3-4 colores (3-4 puntos)	5-6 colores (5-6 puntos)
Arquitectura: regular vs irregular	Irregularidades despreciables (0 puntos)	Irregularidades moderadas (1 punto)	Irregularidades marcadas (2 puntos)
Simetría vs. Asimetría (considerando contorno, colores y estructuras)	Simetría en 2 ejes (0 puntos)	Simetría en 1 eje (1 punto)	Sin simetría (2 puntos)
Homogeneidad vs. Heterogeneidad (considerando la presencia de redes pigmentadas, manchas o glóbulos, zonas de regresión, velo azul blanquecino...)	Una única estructura (1 punto)	2 tipos de estructuras (2 puntos)	3 o más estructuras (3-7 puntos)

Tabla 2-4 - Puntuación CASH

Tras sumar la puntuación total en CASH se clasifica la lesión como:

“Probablemente benigna” si la puntuación es igual o menor que 7

“Sospechosa de melanoma” si la puntuación es igual o mayor que 8

2.5. CHAOS & CLUES

CHAOS & CLUES es un algoritmo de diagnóstico basado en el análisis de patrones [13] [14] que se apoya en la observación de asimetrías en la estructura y/o color de la lesión, y en la detección de “pistas” que puedan indicar malignidad.

El documento [13] describe en primer lugar las cinco diferentes estructuras que pueden distinguirse en una lesión pigmentada: líneas, pseudópodos, círculos, manchas y puntos; dentro de líneas distingue además entre cinco tipos de estructuras: reticular, ramificada, paralela, radial y curvada. Zonas suficientemente grandes para ser consideradas un patrón independiente pero sin predominancia de ninguna de estas estructuras se denominan “sin estructura”.

Por otra parte, el documento define un total de nueve colores que pueden encontrarse en una lesión pigmentada, explicando además el significado de cada uno de estos colores; ya que estos pueden dar información sobre la profundidad de la melanina en la dermis, la presencia de sangre oxigenada o no oxigenada, etc. (características que pueden ser de gran relevancia en el diagnóstico).



Figura 2-1 - Colores en CHAOS & CLUES

El algoritmo busca en primer lugar la presencia de *chaos* (asimetría en color o estructura); en caso de no encontrarse, se finaliza la inspección de la muestra, considerando que no es sospechosa de malignidad.

I. Marco contextual

En caso de encontrar *chaos*, se procede a la búsqueda minuciosa de *clues* –pistas- de malignidad. Las posibles *clues* que se describen en el documento son las siguientes:

1. Área sin estructura y situada fuera del centro de la lesión.
2. Líneas gruesas con estructura reticular o ramificada.
3. Estructuras grises o azuladas (indican una localización más profunda en la dermis de la melanina).
4. Manchas o puntos oscuros en la periferia.
5. Líneas o pseudópodos con distribución radial.
6. Líneas blancas.
7. Venas polimórficas (más de un patrón estructural).
8. Distribuciones no paralelas en lesiones acrales o caóticas en lesiones bajo las uñas.
Estos patrones deben ser considerados sospechosos incluso en ausencia de chaos.

En caso de encontrarse alguna de estas *clues*, se recomienda la extirpación y biopsia de la lesión, a menos que se pueda diagnosticar inequívocamente como un caso de queratosis seborreica [13]. En caso contrario, se considera irrelevante la lesión.

La Figura 2-2 muestra el esquema del algoritmo completo.

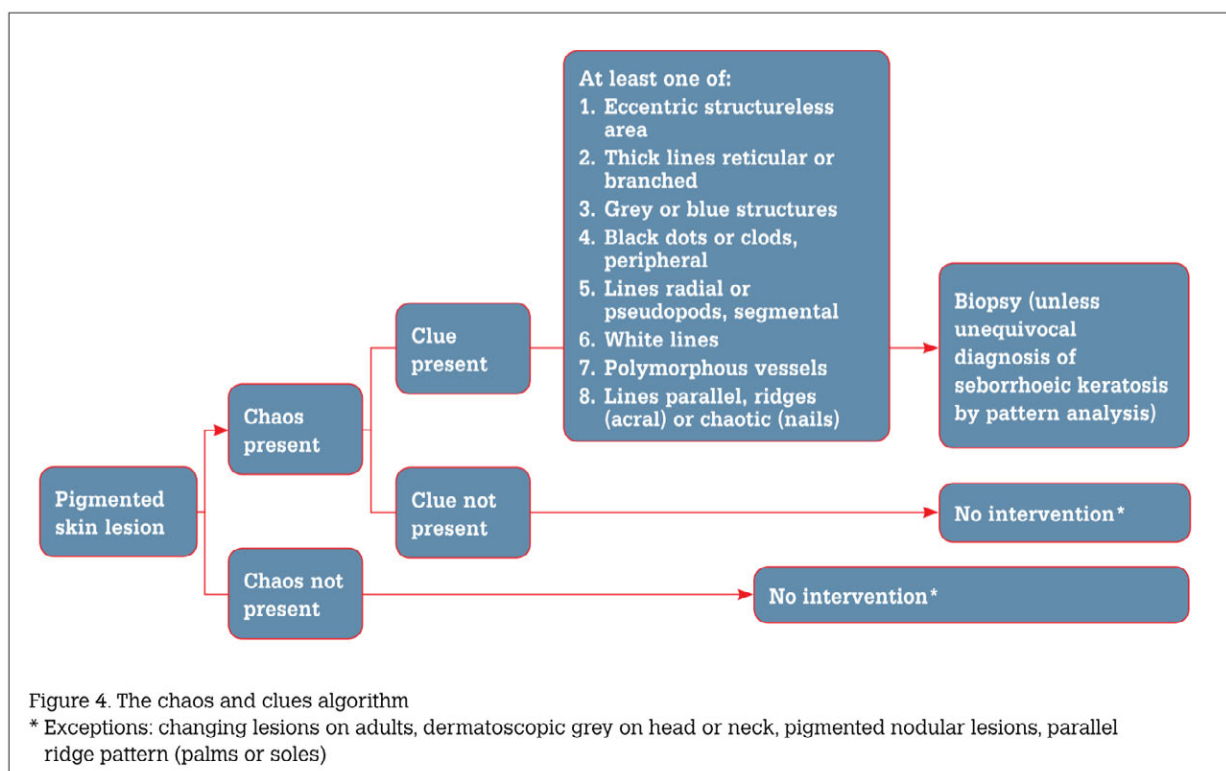


Figura 2-2 - Algoritmo CHAOS & CLUES

El documento concluye especificando cuatro excepciones a la regla de que cualquier lesión simétrica deba ser considerada benigna:

- a) Lesiones que evolucionen con el tiempo, en personas adultas.
- b) Lesiones en la cabeza o cuello con coloración grisácea.
- c) Lesiones nodulares pigmentadas.
- d) Lesiones acrales con patrones paralelos.

3. Estado del arte de la dermatoscopia

La dermatoscopia es una técnica no invasiva de diagnóstico ampliamente utilizada en el campo de la dermatología.

Antes de la aparición de la dermatoscopia, la única forma fiable de determinar la presencia del melanoma consistía en la realización de una biopsia de la lesión para su posterior análisis utilizando un microscopio convencional. La biopsia es un procedimiento invasivo consistente en la extracción de una parte del tejido a estudiar; es por tanto un procedimiento que provoca molestias al paciente, así como gastos médicos adicionales.

La dermatoscopia consiste en la utilización de un instrumento óptico llamado dermatoscopio, que permite una observación detallada *in situ* de las lesiones de la piel, que permite al profesional sanitario detectar estructuras y características que puedan indicar malignidad, y decidir en base a ello la conveniencia de realizar una biopsia o extirpar la lesión.

El dermatoscopio convencional consiste en un microscopio manual con capacidades de ampliación de 10 o más aumentos, así como una fuente de luz convencional o polarizada. La utilización de polarización cruzada junto con una interfase líquida de agua, aceite o alcohol entre la lesión y la lente permite reducir los efectos de la reflexión y refracción de la luz, con el fin de poder apreciar estructuras anatómicas de la epidermis. Ésta es la herramienta más comúnmente utilizada por dermatólogos para evaluar rápidamente las lesiones de los pacientes que acuden a consulta.



Figura 3-1 - Dermatoscopio manual HEINE



Figura 3-2 - Dermatoscopio manual DERMLITE

Como evolución natural de la dermatoscopia tradicional surge la dermatoscopia digital, que combina las herramientas ópticas del dermatoscopio con las técnicas de captura de imagen para obtener representaciones digitales de las lesiones. Esto presenta numerosas ventajas, como la posibilidad de aplicar técnicas de procesamiento de imagen para mejorar su calidad y analizar las características de la lesión, así como implementar sistemas de clasificación automática que aceleren el diagnóstico.

Una de las mayores ventajas de la dermatoscopia digital es que posibilita realizar un seguimiento preciso de la evolución de las lesiones en el tiempo. De esta forma es posible detectar cambios en lesiones a priori benignas, y controlar la evolución de nevus atípicos, que no malignizan necesariamente, evitando biopsias innecesarias. Pero además de estudiar individualmente las lesiones, facilita controlar la aparición de lesiones nuevas, una tarea complicada en pacientes con muchos lunares.

Diferentes fabricantes ofrecen equipos de este tipo, como FotoFinder o MoleMax, aunque su elevado precio hace que su utilización en centros de salud y hospitales aún no esté muy extendida.



Figura 3-3 – FotoFinder



Figura 3-4 – MoleMax

Los avances y la expansión de la electrónica de consumo y en particular de los *smartphones*, han propiciado últimamente la aparición de tecnologías que pretenden acercar las herramienta de diagnóstico al público general.

Algunos ejemplos son la aplicación FotoSkin, ideada por un dermatólogo español e impulsada por el laboratorio ISDIN y liberada en abril de 2014. La aplicación ofrece información general sobre el melanoma, datos en tiempo real sobre los índices de radiación UV, y permite al usuario realizar un control de sus lunares realizando fotografías con la cámara del *smartphone*.




Figura 3-5 - App FotoSkin

I. Marco contextual

Otro proyecto interesante es MoleScope, un dispositivo óptico que se acopla a la cámara del *smartphone* para permitir la digitalización de las lesiones. Viene acompañado por un software que permite el análisis automático de las imágenes y su envío al dermatólogo mediante una aplicación de tele-medicina.



Figura 3-6 - MoleScope

Aunque este tipo de aplicaciones no son equiparables hoy en día a los equipos profesionales, el rápido desarrollo de la tecnología sugiere que en un futuro podrían llegar a ser una alternativa perfectamente viable, siempre con la participación de los profesionales de la salud y complementada con avances en los tratamientos.

4. Técnicas de procesamiento de imagen

A lo largo del desarrollo de este trabajo se va a hacer referencia a numerosos conceptos y procedimientos de procesamiento de imagen digital que se han utilizado para analizar las imágenes dermatoscópicas. El objetivo de este apartado es realizar un resumen de estos conceptos.

4.1. Archivos de imagen y sistemas de color

Para representar el color existen diferentes modelos que presentan distintas características y ventajas de cara a su tratamiento. En general estos modelos representan cada color mediante un vector de tres o cuatro valores numéricos. Entre los modelos más comúnmente utilizados, se encuentran los siguientes:

- El modelo RGB representa el color como la mezcla aditiva de los tres colores primarios: rojo (R), verde (G) y azul (B), con diferentes valores de luminosidad. Es un modelo muy utilizado ya que proporciona información sobre cada color primario por separado, aunque su representación depende de cómo esté definido cada color primario en el dispositivo de visualización.
- El modelo HSV representa el color como una combinación de tonalidad o *hue* (H), saturación (S) y intensidad (*value*, V). Este modelo tiene algunas ventajas como independizar la información de tonalidad y la del brillo, pudiendo modificarlas de forma independiente. Una representación habitual de este espacio de color es la rueda de color mostrada en la Figura 4-1.




Figura 4-1 - Rueda de color HSV

- El modelo YCbCr codifica por un lado la intensidad del color (Y) y por otro lado la crominancia, o diferencia de azul y de rojo. Es un modelo muy utilizado en vídeo y fotografía digital ya que optimiza el ancho de banda necesario para representar la información de luminancia y cromática por separado, disminuyendo la redundancia.

El término “profundidad de color” hace referencia a la gama total de colores diferentes que es posible representar con un modelo de color en función del número de bits con el que se codifique cada píxel. El siguiente ejemplo explica este concepto:

La profundidad de color de 24 bits, denominada comúnmente *true color* (color verdadero) por su semejanza con la resolución de colores percibida por el ojo humano, codifica con 8 bits cada

I. Marco contextual

uno de los tres canales de color. De esta forma, cada canal puede tomar valores entre 0 y 255, y en total pueden representarse $2^8 \cdot 2^8 \cdot 2^8 = 2^{24} = 16.777.216$ colores diferentes.

Existen numerosos formatos de archivo de imagen. Una clasificación importante que se puede realizar de estos formatos es entre formatos con y sin compresión. La compresión de imagen, a su vez, puede ser con pérdidas y sin ellas. La compresión sin pérdidas aprovecha la redundancia de la información para aplicar algoritmos que reducen el tamaño del archivo pero permiten reconstruirlo posteriormente sin pérdida de información. Por el contrario, la compresión con pérdidas explota las limitaciones de la percepción humana para reducir la información menos relevante, obteniendo versiones aproximadas de la imagen original con menor tamaño de archivo y difíciles de distinguir de éstas; no obstante, no posibilitan la recuperación de la imagen original una vez comprimidas. Por ello, en el campo del procesamiento de imagen se trabaja generalmente con formatos sin compresión o con compresión sin pérdidas, ya que la información eliminada que puede no ser perceptible para la visión humana sí puede ser necesaria para el procesamiento digital.

En este caso concreto se trabajará con archivos en formato bitmap (.BMP), un formato de imagen no comprimida o con compresión sin pérdidas. Las imágenes son *true color*, esto es, tienen una profundidad de color de 24 bits.

4.2. Propiedades de la imagen

Es posible cuantificar una serie de propiedades de las imágenes que pueden ser útiles a la hora de procesarlos. En este apartado se hace un breve resumen de las más importantes. Nos centraremos en el estudio de imágenes monocromas, siendo posible extrapolar estos métodos a imágenes con varios canales de color mediante la combinación de estos o el procesamiento de cada uno por separado.

A la hora de analizar el contenido de una imagen monocroma, una de las aproximaciones es obtener la distribución estadística de los niveles de intensidad de todos sus píxeles. Esto se representa generalmente mediante el histograma de la imagen, un gráfico de barras que representa la frecuencia de cada valor de intensidad (o “nivel de gris”) en la imagen. En ocasiones estos niveles de gris pueden agruparse en cubos o *bins*, de forma que se contabilizan todos los niveles dentro del rango de un determinado *bin*. También es habitual normalizar el histograma respecto al nº total de píxeles de la imagen, de forma que represente las frecuencias relativas de cada nivel de intensidad.

El estudio del histograma permite extraer información interesante acerca de la imagen. Por ejemplo, una imagen con poco contraste tendrá un histograma muy concentrado en torno a un valor de luminosidad, mientras que otra con gran contraste presentará una distribución más uniforme de sus niveles de gris, cubriendo un mayor rango de niveles de gris.

En ocasiones la distribución estadística de los niveles de intensidad en una imagen no es apropiada o dificulta la posterior interpretación de la información. Una técnica habitual de pre-procesado de imagen es aplicar funciones de transferencia que provoquen una compresión o expansión del histograma, o lo desplacen para, por ejemplo, igualar la luminosidad media de dos imágenes.

Otra forma habitual de estudiar las imágenes es hacerlo en el dominio de la frecuencia, obteniendo la transformada discreta de Fourier bidimensional (DFT). Antes de nada es necesario entender el significado de la información espectral en las imágenes.

De esta forma, la información de alta frecuencia se corresponde con variaciones de intensidad en espacios más pequeños –por ejemplo en zonas con bordes, ruido o con texturas complejas- mientras que la baja frecuencia indica cambios más progresivos y dilatados en el espacio.

Trabajando en este dominio permite, por ejemplo multiplicar la representación de la DFT bidimensional de una imagen con ruido de alta frecuencia por la función de transferencia de un filtro paso bajo y, aplicando la transformada inversa (IDFT), recuperar una versión restaurada de la imagen original que presente menos ruido. De la misma forma es posible mediante un filtro paso alto realzar los bordes, o utilizar un filtro paso banda para realzar una textura con una información espectral determinada.

4.3. Segmentación de imagen

En el campo del procesado de la imagen y la visión artificial, el concepto de segmentación [15] engloba el conjunto de técnicas y procesos que hacen posible localizar y separar determinados objetos de interés en la imagen, con el fin de facilitar su posterior procesado o extraer únicamente la información de interés. En la práctica el resultado de la segmentación es la asignación de etiquetas a los píxeles que, por sus características, se consideran parte de un objeto determinado.

Los algoritmos de segmentación típicos se basan o bien en la detección de discontinuidades en el nivel de gris de la imagen, o agrupando zonas con características similares.

Segmentación basada en discontinuidades

Los algoritmos basados en discontinuidades trabajan detectando cambios bruscos de nivel de intensidad en la imagen. Una posible forma de hacer esto es pasar una máscara a través de la imagen que permita obtener para cada punto la diferencia ponderada entre su valor de luminosidad y el de los píxeles vecinos, y aplicar un umbral para seleccionar los cambios más bruscos. Por ejemplo, para detectar un punto se podría aplicar una máscara como la de la Figura 4-2

-1	-1	-1
-1	8	-1
-1	-1	-1

Figura 4-2 - Máscara detección de puntos

El valor asignado al píxel estudiado (el central) se calcularía de acuerdo con la ecuación 4-1, donde R es la suma de los niveles de gris de los 9 píxeles multiplicados por cada coeficiente de la máscara, y T es el valor umbral (umbrales más altos limitarán la detección a los puntos más acusados de la imagen, y viceversa).

$$f(x) = \begin{cases} 1 & \text{si } |R| > T \\ 0 & \text{si } |R| \leq T \end{cases} \quad (4-1)$$

I. Marco contextual

Utilizando esta misma técnica es posible diseñar máscaras para detectar otro tipo de discontinuidades. Por ejemplo, la máscara de la Figura 4-3 serviría para detectar líneas horizontales.

-1	-1	-1
2	2	2
-1	-1	-1

Figura 4-3 - Máscara detección de líneas horizontales

La utilidad de los detectores de puntos y líneas está limitada a aplicaciones concretas, ya que las discontinuidades que se encuentran normalmente en las imágenes tienen un carácter más complejo. Una solución más potente a este tipo de problemas es la utilización de detectores de bordes. Estos se basan en el estudio de la derivada local para detectar cambios bruscos de luminosidad en la imagen. Su modo de trabajo habitual es aplicar la máscara y posteriormente una umbralización para seleccionar los cambios más abruptos ³.

Para ello se aplican diferentes máscaras a los píxeles, existiendo diferentes tipos de detectores en función del tipo de máscara empleada:

- Operadores basados en el gradiente (primera derivada); se detallan los más comunes:
 - Roberts: el más sencillo, utiliza máscaras de 2x2, lo que lo convierte en una solución eficiente únicamente para procesar imágenes binarias y con bordes verticales y horizontales.
 - Sobel: este operador resulta de la combinación de una función de suavizado y una aproximación del gradiente a fin de reducir la influencia del ruido en torno al punto estudiado. Pueden combinarse las máscaras de la aproximación del gradiente horizontal y vertical para mejorar la detección de bordes diagonales.
 - Prewitt: funciona de forma similar al de Sobel, aunque no enfatiza la importancia de los píxeles cercanos al central.

Es posible utilizar versiones de estos operadores con dimensiones superiores a 3x3 con el fin de reducir aún más la influencia del ruido en el entorno del punto de estudio. Esto aumenta el número de operaciones a realizar por cada píxel, y por tanto el tiempo de cálculo; por lo que en ocasiones puede ser preferible reducir el ruido por otros métodos previamente a la detección de bordes.

Los operadores de Roberts, Sobel y Prewitt trabajan con el módulo de la derivada. Existen otros operadores, como el de Frei-Chen o el de Kirsch, que permiten obtener la variación de la intensidad en una dirección determinada.

- Operadores basados en el laplaciano (segunda derivada): el operador laplaciano se obtiene a partir de la suma de las segundas derivadas en las direcciones x e y. A diferencia del gradiente, el laplaciano es un escalar. Es un operador isotrópico (invariante a la rotación), lo que supone una ventaja importante en ciertas aplicaciones. La presencia

³ Estos operadores pueden utilizarse también para realzar bordes, no aplicándose en tal caso la umbralización.

de un borde se caracteriza por un máximo o un mínimo en la primera derivada en una dirección determinada, y por tanto un paso por cero de la segunda derivada; por ello el operador laplaciano funciona buscando valores cercanos a ceros de la segunda derivada.

La principal desventaja del operador laplaciano es su sensibilidad frente al ruido, por lo que en imágenes ruidosas es necesaria una etapa previa de suavizado de la imagen.

- Operador LoG (*Laplacian Of Gaussian*): aplica el operador laplaciano a una imagen previamente suavizada mediante un filtro gaussiano, lo que reduce en gran medida la influencia del ruido. El filtrado gaussiano difumina los bordes, por lo que es necesario aplicar una umbralización a la primera derivada para evitar que se consideren bordes poco significativos.
- Operador de Canny: este operador, que puede considerarse el más sofisticado, combina varias características que lo convierten en un detector de bordes que se adapta a imágenes de todo tipo, con mayor o menor presencia de ruido, produciendo buenos resultados sin mayor coste computacional. Combina una etapa de reducción de ruido mediante filtrado gaussiano con el cálculo del gradiente, seguido de una búsqueda para evitar la supresión de máximos locales, y aplica una umbralización adaptativa mediante histéresis. Los parámetros de configuración del operador de Canny son el tamaño del filtro gaussiano y los dos umbrales extremos para el algoritmo de histéresis.

Segmentación basada en similitud

Otros métodos de segmentación se basan en la agrupación de zonas de la imagen cuyos píxeles compartan características semejantes, como el color o la intensidad. Dentro de estos métodos, cabe destacar la umbralización y el crecimiento de regiones.

La umbralización es uno de los métodos más importantes y empleados en la segmentación de imágenes, por su simplicidad y bajo coste computacional. Consiste en asignar un valor o etiqueta a cada píxel en función de si su valor de intensidad es superior o inferior a un umbral.

$$g(x,y) = \begin{cases} 1 & \text{si } f(x,y) > T \\ 0 & \text{si } f(x,y) \leq T \end{cases} \quad (4-2)$$

De acuerdo con la ecuación, el valor asignado al píxel de coordenadas (x,y) en la máscara g(x,y) será 1 si el valor de luminosidad de dicho píxel en la imagen f(x,y) supera al umbral definido, T; y 0 en caso contrario.

En imágenes en las que los niveles predominantes de intensidad estén bien definidos, es posible aplicar una umbralización multinivel –esto es, con varios umbrales, distinguiendo más de dos objetos diferentes–, pero en general, la dificultad de elegir dichos umbrales hace que en muchas ocasiones un umbral único proporcione segmentaciones más precisas.

La elección del valor umbral es el problema principal en este tipo de segmentación, y existen dos soluciones típicas:

- Umbralización global simple: el método más sencillo divide el histograma de la imagen utilizando un umbral único, T, en base al cual se etiquetarán todos los píxeles. Este método puede ser apropiado en imágenes con los objetos bien diferenciados y una iluminación uniforme. Una forma habitual de escoger este valor umbral global es el que implementa el algoritmo de Otsu [16], que maximiza la dispersión de los niveles de gris dentro de cada clase y maximiza la dispersión entre dos clases diferentes (en la práctica,

I. Marco contextual

esto se consigue haciendo máximo el cociente entre la varianza intra-clase y la varianza inter-clase).

- Umbralización local. Cuando las condiciones de iluminación de la imagen son irregulares, la segmentación mediante un umbral único puede no resultar suficientemente precisa. Esto se puede resolver dividiendo la imagen en regiones y calculando umbrales locales específicos para cada región; la desventaja de esta forma de trabajo es que la calidad de la segmentación puede ser menor en las fronteras entre regiones con umbrales muy distintos. Una alternativa es la del umbral dinámico, en el que se determinan los umbrales a partir de regiones en torno a cada píxel, lo que permite que los umbrales calculados varíen de forma más gradual.

Segmentación orientada a regiones

Los métodos basados en píxeles, como la umbralización, permiten de forma rápida clasificar los píxeles de la imagen en categorías, pero no garantizan que aparezcan agrupados en objetos distinguibles en el resultado de la segmentación, obligando generalmente a utilizar operaciones morfológicas (ver más adelante) para agruparlos. La segmentación orientada a regiones se aproxima al problema de una forma diferente y tiene dos modos principales de trabajo:

- Crecimiento de regiones por agregación de píxeles: este tipo de algoritmos comienzan a partir de un conjunto de “puntos generadores”, a los que se van agregando los píxeles contiguos en función de la similitud de sus características. Generalmente, conforme la región crece se actualizan los valores de referencia (p.ej. su nivel de intensidad medio) para la selección de los píxeles cercanos.
- División y fusión de regiones: en este caso se comienza con una subdivisión arbitraria de la imagen y se comienza un proceso iterativo en el que se continúa subdividiendo las regiones cuyo contenido no presente aún la homogeneidad deseada. Esto puede dar lugar a regiones disjuntas con propiedades muy parecidas, por lo que se complementa con la fusión de estas regiones mediante el método anterior (crecimiento de regiones). La división se realiza habitualmente en cuadrantes, por lo que esta técnica también se conoce como “árbol múltiple” [15].

La elección de uno u otro método puede realizarse en base a la información previa de la imagen: por ejemplo, si se conoce de forma aproximada la posición de los objetos a segmentar, la selección de los puntos generadores es más sencilla y el método de crecimiento de regiones puede dar buenos resultados; si no se conoce la distribución de los objetos en la imagen, la división y fusión de regiones puede resultar más apropiada.

El resultado de un proceso de segmentación de la imagen consiste en general en el etiquetado de los píxeles, de forma que el conjunto de píxeles con la misma etiqueta pertenecen al mismo objeto. En el caso más sencillo, este resultado será una matriz de $H \times W$ (siendo H y W el número de píxeles de la imagen segmentada en vertical y horizontal, respectivamente) con dos posibles valores: 0 y 1. Los píxeles con valor 0 constituirían generalmente el “fondo” y los píxeles con valor 1 el “objeto segmentado”. Es lo que se conoce como imagen o máscara binaria.

4.4. Operaciones morfológicas

Como hemos visto en el apartado anterior, la calidad de la segmentación depende de factores como la iluminación, el contraste o el ruido presente en la imagen. Para mejorar el resultado se recurre habitualmente al empleo de operaciones morfológicas, que trabajan a nivel de píxel modificando las formas segmentadas. Dentro de estas técnicas, cabe destacar dos principales – dilatación y erosión- y otras dos que son combinación de las primeras –apertura y cierre.

Las operaciones morfológicas se realizan utilizando elementos estructurales, que son matrices de unos y ceros que definen la forma y la dimensión de la operación a aplicar. Antes de nada, definiremos algunos conceptos básicos:

- A y B conjuntos en \mathbb{R}^2 , y \emptyset el conjunto vacío.
- La traslación de A por $x = (x_1, x_2)$

$$(A)_x = \{c | c = a + x, \text{ para } a \in A\} \quad (4-3)$$

- La reflexión de B

$$\hat{B} = \{x | x = -b, \text{ para } b \in B\} \quad (4-4)$$

- El complemento del conjunto A

$$A^c = \{x | x \notin A\} \quad (4-5)$$

- La diferencia de dos conjuntos A y B

$$A - B = A \cap B^c \quad (4-6)$$

- Dilatación: se utiliza para ensanchar los objetos. La dilatación de A por B se representa en 4-7. En la práctica, se refleja y traslada el elemento estructural B por la imagen y se ponen a 1 los píxeles de A en aquellas posiciones x en las que la intersección de A y B reflejada y desplazada no es nula.

$$A \oplus B = \{x | (\hat{B})_x \cap A \neq \emptyset\} \quad (4-7)$$

- Erosión: se emplea para adelgazar la imagen. De acuerdo con la ecuación 4-8, el resultado de la erosión es el conjunto de posiciones x para los cuales el elemento estructural B reflejado y desplazado está contenido en A.

$$A \ominus B = \{x | (B)_x \subseteq A\} \quad (4-8)$$

- Apertura: consiste en erosionar A por B, y a continuación dilatar el resultado por B. Se consigue un efecto de suavizado del contorno de los objetos, eliminando pequeñas protuberancias.

$$A \circ B = (A \ominus B) \oplus B \quad (4-9)$$

- Cierre: al contrario que la apertura, realiza en primer lugar una dilatación y a continuación una erosión. Esto permite fusionar objetos muy cercanos o eliminar pequeños huecos.

$$A \cdot B = (A \oplus B) \ominus B \quad (4-10)$$

I. Marco contextual

A partir de estas cuatro técnicas se desarrollan algoritmos morfológicos que desempeñan otro tipo de funciones. Por ejemplo, la ecuación 4-11 representa una forma de extraer únicamente el contorno de un objeto.

$$\beta(A) = A - (A \ominus B) \quad (4-11)$$

5. Técnicas de clasificación

El objetivo de las técnicas de clasificación es asignar a cada elemento de un conjunto la pertenencia a una clase determinada. Las clases identifican a un conjunto de elementos que comparten cierta similitud en una serie de características [17]. Las distintas clases definidas dependen de la aplicación. Por ejemplo, en este caso el objetivo es distinguir entre dos clases de lesiones: las que son benignas y las que pueden ser melanoma.

Características son todas aquellas propiedades de un elemento que pueden ser de alguna forma cuantificadas. En el caso que nos ocupa las características de una lesión podrían ser, por ejemplo, la media y la desviación estándar de los niveles de luminosidad de la imagen, el perímetro de la lesión, el área, la orientación... estas son características relativamente simples, pero también podemos hablar de características de mayor complejidad, como el tipo de textura, la dispersión del color, etc.

Es importante destacar que pese a que el número de características que se pueden observar en un objeto es prácticamente ilimitado, no todas son necesariamente relevantes a la hora de distinguirlo de otro objeto. Además, algunas características puede estar correladas entre sí o, por el contrario, tener un carácter aleatorio o no estar correladas con el resto de propiedades del objeto. Todo ello lleva a la necesidad de determinar las características relevantes de cada objeto en función de la aplicación. Sobre este concepto profundizaremos más adelante.

Como hemos comentado anteriormente, en esta aplicación el problema de clasificación se reduce a la clasificación entre dos clases determinadas: lesiones benignas y malignas. Es lo que se conoce como clasificación supervisada.

La clasificación supervisada se basa en la disponibilidad de datos de entrenamiento, de los que se conoce a qué clase pertenecen; extrayendo características de estos elementos es posible diseñar un algoritmo clasificador que asigne a muestras futuras una clase determinada en función de sus características. Existen numerosos algoritmos de este tipo, como son las redes neuronales artificiales, SVM, árboles de decisión, *Naïve Bayes*, *Random Forests*, etc.

Se conoce como *ground truth* a la información objetiva acerca de los elementos del conjunto de entrenamiento que se conoce previamente y que se utiliza para evaluar el sistema. En el mundo de la medicina es común el empleo del término *gold standard* [18] para referirse a un diagnóstico realizado en las mejores condiciones; aunque puede no ser totalmente preciso objetivamente, se considera la referencia válida para evaluar a otros sistemas.

La clasificación no supervisada, por otro lado, se emplea para procesar datos de los que no se tiene conocimiento inicial, con el fin de detectar distintas estructuras y clases, agrupando elementos que tengan características similares. Dentro de esta categoría se incluyen las técnicas de *clustering* o agrupamiento, como el algoritmo *k-means*.

Habitualmente se diseñan estos algoritmos con la intención de que sean capaces de adaptarse y ajustarse para mejorar la clasificación de nuevos datos de entrada, por lo que de manera más habitual se habla de “aprendizaje de máquinas”.

A la hora de evaluar un clasificador, se emplean los siguientes parámetros:

- Verdadero positivo o *true positive* (TP): porcentaje de muestras positivas clasificadas correctamente como positivas.
- Verdadero negativo o *true negative* (TN): porcentaje de muestras negativas clasificadas correctamente como negativas.
- Falso positivo o *false positive* (FP): porcentaje de muestras negativas clasificadas incorrectamente como positivas.
- Falso negativo o *false negative* (FN): porcentaje de muestras positivas clasificadas incorrectamente como negativas.

Resulta evidente que un buen clasificador deberá presentar elevadas tasas de TP y TN frente a FP y FN; sin embargo, el énfasis en TP o en TN dependerá de la aplicación.

En el campo del diagnóstico clínico, en general se utiliza el término “positivo” para referirse a los casos diagnosticados como enfermos, y “negativo” en el caso contrario. En lugar de la nomenclatura TN, TP, FN y FP, se utilizan generalmente los siguientes valores:

- Sensibilidad: se define como la probabilidad de clasificar como enfermos los casos realmente enfermos. La sensibilidad es del 100% cuando no se ha producido ningún falso negativo.

$$\text{Sensibilidad} = \frac{TP}{TP+FN} \quad (5-1)$$

- Especificidad: probabilidad de clasificar como sanos los casos realmente sanos. La especificidad es del 100% cuando no se ha producido ningún falso positivo.

$$\text{Especificidad} = \frac{TN}{TN+FP} \quad (5-2)$$

- Finalmente, cabe hablar de la precisión de un clasificador como el porcentaje global de acierto de éste. Evidentemente, la precisión es del 100% cuando no se producen ni falsos positivos ni falsos negativos.

$$\text{Precisión} = \frac{TN+TP}{TN+TP+FN+FP} \quad (5-3)$$

I. Marco contextual

II. Antecedentes

A lo largo de los últimos años han aparecido numerosos trabajos de investigación en el ámbito de la visión artificial aplicada al análisis y clasificación de imágenes dermatoscópicas.

La segmentación correcta de la lesión en las imágenes dermatoscópicas es uno de los primeros problemas que se plantean a la hora de desarrollar software de este tipo y ha dado pie a numerosas aportaciones de la comunidad investigadora. En [19], [20] se evalúan distintos métodos para la detección del contorno de las lesiones. En [21], [22] se proponen varios algoritmos de segmentación y métodos para la eliminación de pelos en la imagen. [22] utiliza para la segmentación la información el mapa de color de la imagen dermatoscópica. En [23] se propone un método de segmentación preciso y rápido capaz de ser ejecutado en un *smartphone*. Los autores de [24] utilizan el análisis de componentes principales (PCA) como ayuda para la segmentación de regiones de interés. Por otro lado, los responsables de la realización de la base de datos de imágenes dermatoscópicas PH², utilizada en este trabajo, presentan en [25] una herramienta para facilitar la segmentación manual de las lesiones por parte de los dermatólogos.

En el ámbito de la extracción de características de las lesiones existen también numerosos trabajos, que por comodidad clasificaremos de acuerdo con la regla ABCD:

- Estudio de asimetría: es un problema complejo ya que no parece existir un consenso en cuanto a qué características indican asimetría en la lesión. La mayoría de los trabajos estudiados, como [22], [21], [26], [27] realizan un estudio de asimetría basado únicamente en el contorno de la lesión; otros ([28], [29]) tienen en cuenta también el contenido de la lesión. En [30] se aborda de forma general el problema de la evaluación y detección de simetría en imágenes en escala de grises.
- Estudio del borde. Aunque la irregularidad del borde no es una característica tan relevante como otras en los algoritmos de diagnóstico, se proponen métodos para su estudio en [28], [21], y [28].
- Estudio de colores. Como hemos visto anteriormente, presencia de diferentes tonalidades en una lesión tiene relevancia diagnóstica. Dado que en el campo de procesado de imagen médica generalmente se trabaja con imágenes en escala de grises, no existe tanta bibliografía al respecto. Un método interesante de segmentación de colores es el propuesto en [24], que utiliza el análisis de componentes principales para obtener un histograma bidimensional de la información de color de la imagen, que es posteriormente procesado para segmentar las zonas con diferente tonalidad.
- Estudio de diferencias estructurales. Las características más estudiadas son el velo azul/blanquecino y la red pigmentada. En [31], [24] y otros se proponen métodos para localizar la presencia del velo azul-blancuecino. La detección del retículo pigmentado se trata en [24], [32]. Otro tipo de estructuras estudiadas en algunos trabajos son los puntos y glóbulos [33] o las áreas de regresión [24].

II. Antecedentes

En cuanto a la clasificación automática de las lesiones analizadas, es de destacar que un gran número de estos trabajos se centran exclusivamente en la extracción de ciertas características y estructuras de la lesión de forma orientada a su diagnóstico por medio de alguno de los métodos existentes. En [21] se utiliza la regla ABCD, [24] se basa en el método *7-point checklist*.

Otros trabajos proponen otras formas de clasificación basadas en el análisis de patrones. En [22] se realiza la clasificación mediante varios métodos diferentes (*Support Vector Machines*, *K-Nearest Neighbours* y análisis discriminante lineal) y posteriormente se comparan resultados. En [28] se realizan pruebas mediante contraste de hipótesis y análisis discriminante lineal. En [27] se estudia el rendimiento de clasificadores SVM, *Random Forest* (RF), *Logistic Model Trees* (LM) y *Hidden Naïve Bayes* (HNB) utilizando diferentes selecciones de características.

Algunos de estos documentos, como [22], [28], [29], [24] proponen sistemas completos de pre-procesado de la imagen, segmentación, extracción de características y clasificación automática, y han sido una importante referencia para la realización de este trabajo.

III. Descripción de la solución propuesta

En los apartados anteriores hemos descrito en qué consiste el melanoma y la necesidad de disponer de métodos de diagnóstico eficientes que permitan detectar las lesiones malignas antes de que se extiendan, detallando los distintos algoritmos utilizados en la actualidad por los dermatólogos. También se han explicado las técnicas principales de procesamiento de imagen y clasificación automática que se utilizan en este campo.

En base a esto se ha optado por desarrollar un software de análisis de imagen que desempeñe las siguientes funciones: segmentar las lesiones a partir de las imágenes de una base de datos, analizar su contenido en búsqueda de características de relevancia diagnóstica y clasificarlas entre lesiones benignas y malignas utilizando algunos de los algoritmos existentes; así como evaluar los resultados contrastándolos con los de *ground truth* incluidos en la base de datos.

Se ha escogido Matlab como lenguaje de programación ya que el enorme número de funciones y utilidades que proporciona, así como su entorno de desarrollo, facilitan la implementación de muchos de los algoritmos diseñados. Además de ser un lenguaje flexible y con capacidades adecuadas para representar visualmente la información de las imágenes procesadas. Se utilizó la versión 2013a Matlab.

En el Anexo I se hace una breve descripción de algunas de las funciones o módulos implementados. Por otro lado, el código implementado contiene abundantes comentarios y texto de ayuda para facilitar su comprensión.

6. Base de datos

Para la realización de pruebas durante el desarrollo del software, así como su posterior evaluación, era necesaria una base de datos de imágenes dermatoscópicas correspondientes tanto a lesiones benignas como a melanomas. Esta base de datos constituye la *ground truth* o *gold standard* de nuestro sistema, conceptos que hemos definido anteriormente en el apartado 5.

La base de datos utilizada es la *PH²* [34], disponible de forma gratuita y pública. Está compuesta por:

- 200 imágenes dermatoscópicas, correspondientes a lesiones benignas y malignas. Son imágenes en formato .bmp, con formato de color 8bit-RGB y una resolución de 768x560 píxeles, obtenidas mediante el sistema Tuebinger Mole Analyzer.
- Segmentación manual de cada una de las muestras, realizada por dermatólogos expertos (Figura 6-2). Algunas lesiones incluyen también la segmentación manual de las regiones que presentan una pigmentación específica (Figura 6-3, Figura 6-4)
- Diagnóstico clínico, identificado mediante los valores 0 (“nevus”), 1 (“nevus atípico”) y 2 (“melanoma”)

III. Descripción de la solución propuesta

- Identificación de un conjunto de estructuras relevantes en cada lesión, tales como: asimetría, colores presentes, red pigmentada, manchas, trazos, áreas de regresión, y velo azul-blanquecino.




Figura 6-1 - Imagen RGB de una lesión



Figura 6-3 - ROI del color 4



Figura 6-2 - Segmentación manual de la lesión



Figura 6-4 - ROI del color 5

Los datos correspondientes a cada lesión se proporcionan en un documento de texto plano y en una hoja de cálculo.

Se codificó una función en Matlab para procesar el archivo de texto y extraer los datos de cada lesión, a fin de poder utilizarlos posteriormente.

7. Interfaz de usuario

Para facilitar la utilización del software de diagnóstico, se ha diseñado e implementado una interfaz gráfica de usuario (GUI) que proporcione las siguientes funcionalidades:

- Seleccionar el directorio de trabajo, que contenga las imágenes a analizar, y permitir al usuario seleccionar la muestra que desea procesar.
- Modificar de forma dinámica los parámetros de configuración del programa de procesamiento de imagen, en aquellos casos en los que el resultado de la segmentación automática no sean satisfactorios.
- Escoger el método de diagnóstico a emplear, observar el diagnóstico entregado por el programa y compararlo con el diagnóstico conocido de la base de datos (*ground truth*).
- Procesar automáticamente todas las muestras de la base de datos, utilizando la configuración elegida.

- Activar o desactivar la visualización de las distintas marcas o anotaciones disponibles sobre la imagen tras el procesamiento.

La interfaz gráfica se diseñó utilizando el entorno de desarrollo GUIDE de Matlab, y posteriormente se codificó el comportamiento de cada uno de sus controles. La interfaz ha sido diseñada de forma que su aspecto visual y funcionamiento sean correctos tanto en entornos Windows como en MAC OS.

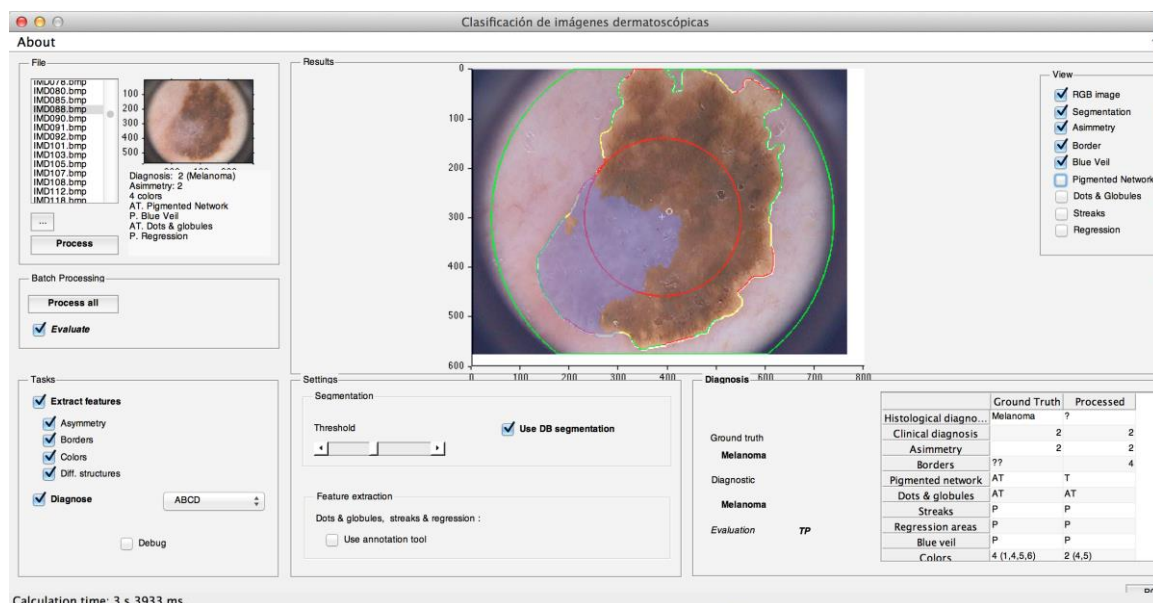


Figura 7-1 - Interfaz Gráfica de Usuario

Se han incluido ayudas contextuales para cada uno de los controles de la interfaz a fin de facilitar su uso. Adicionalmente, en el Anexo II se proporciona una guía de uso del programa.

8. Segmentación de las lesiones

Primeramente se observaron las características de las imágenes de la base de datos PH². Se observó que en algunas de ellas –la mayoría correspondientes a melanomas– la lesión no estaba completamente contenida en la imagen, quedando recortada por uno o más bordes. Por otra parte, la mayoría de las imágenes presentaban una especie de marco oscuro circular o “viñeta” que, como veremos más adelante, podría afectar al alterar la distribución de color de la imagen real.

Se va a utilizar la solución a este último problema como ejemplo de una técnica que se va a utilizar en numerosas ocasiones: la extracción de determinadas partes de la imagen mediante el uso de máscaras binarias. Las máscaras binarias son matrices, generalmente del mismo tamaño que la imagen original, cuyos píxeles pueden tomar únicamente dos valores, 0 o 1. Esto permite utilizarlas de formas:

III. Descripción de la solución propuesta

- Como índices para referenciar determinados píxeles de otra imagen. Por ejemplo, para calcular el histograma de la zona central de la imagen sin que influyesen los bordes oscuros externos, se creó una máscara circular con la ayuda de la función *ndgrid* y se obtuvo el histograma solo en la zona del círculo interior mediante el comando *imhist(image(find(mask==1)))*.
- Multiplicándola por una imagen píxel a píxel (*image.*mask*), de forma que los valores de aquellos que queden fuera de la zona de interés se pongan a 0 y el resto permanezcan inalterados. Esta solución es diferente a la anterior ya que, en este caso, si calculásemos el histograma observaríamos que la frecuencia absoluta del valor “0” aumentaría, al haber considerado todos los píxeles de la imagen para obtenerlo.

Para segmentar la lesión se procedió de la siguiente manera:

- 1) En primer lugar, se pasó la imagen a escala de grises y se utilizó la función *graythresh* para obtener el umbral global óptimo de la imagen. A fin de evitar que los bordes oscuros debidos a las condiciones de toma de las fotografías, se recortó previamente la imagen mediante una máscara binaria circular centrada en el punto medio de la imagen y con radio la mitad de la anchura de la imagen menos un pequeño margen de 20 píxeles.
- 2) Utilizando el umbral calculado y la función *im2bw*, se obtuvo la máscara binaria. Nótese que debido a que la intensidad de la zona de la lesión es siempre menor que la de la piel sana, esta función etiquetará con valor 0 los píxeles de la lesión y con valor 1 los del resto de imagen. Por ello es necesario invertir los valores de la máscara binaria, cambiando los ceros por unos y los unos por ceros.
- 3) Se aplican a la máscara resultante operaciones morfológicas de rellenado de hueco utilizando la función *bwfill*, y se eliminan los objetos con tamaño menor a 30 píxeles mediante *bwareaopen*.
- 4) Se aplica un filtro de mediana con tamaño 10x10 con el fin de suavizar el contorno de las máscaras.
- 5) Finalmente, se selecciona únicamente el objeto de mayor tamaño. Para evitar que al segmentar lesiones pequeñas se escoja la zona de las esquinas, se aplica previamente la máscara de recorte circular y se añaden restricciones para limitar la búsqueda a la zona central de la imagen.
- 6) Finalmente, se obtiene también el contorno de la máscara mediante *bwperim*, y se dilata levemente con un elemento estructural de tipo “disco” para representarlo mejor sobre la imagen.

La Figura 8-1 representa las fases descritas en los puntos 1 a 6, al aplicarse el método a una de las imágenes de la base de datos.

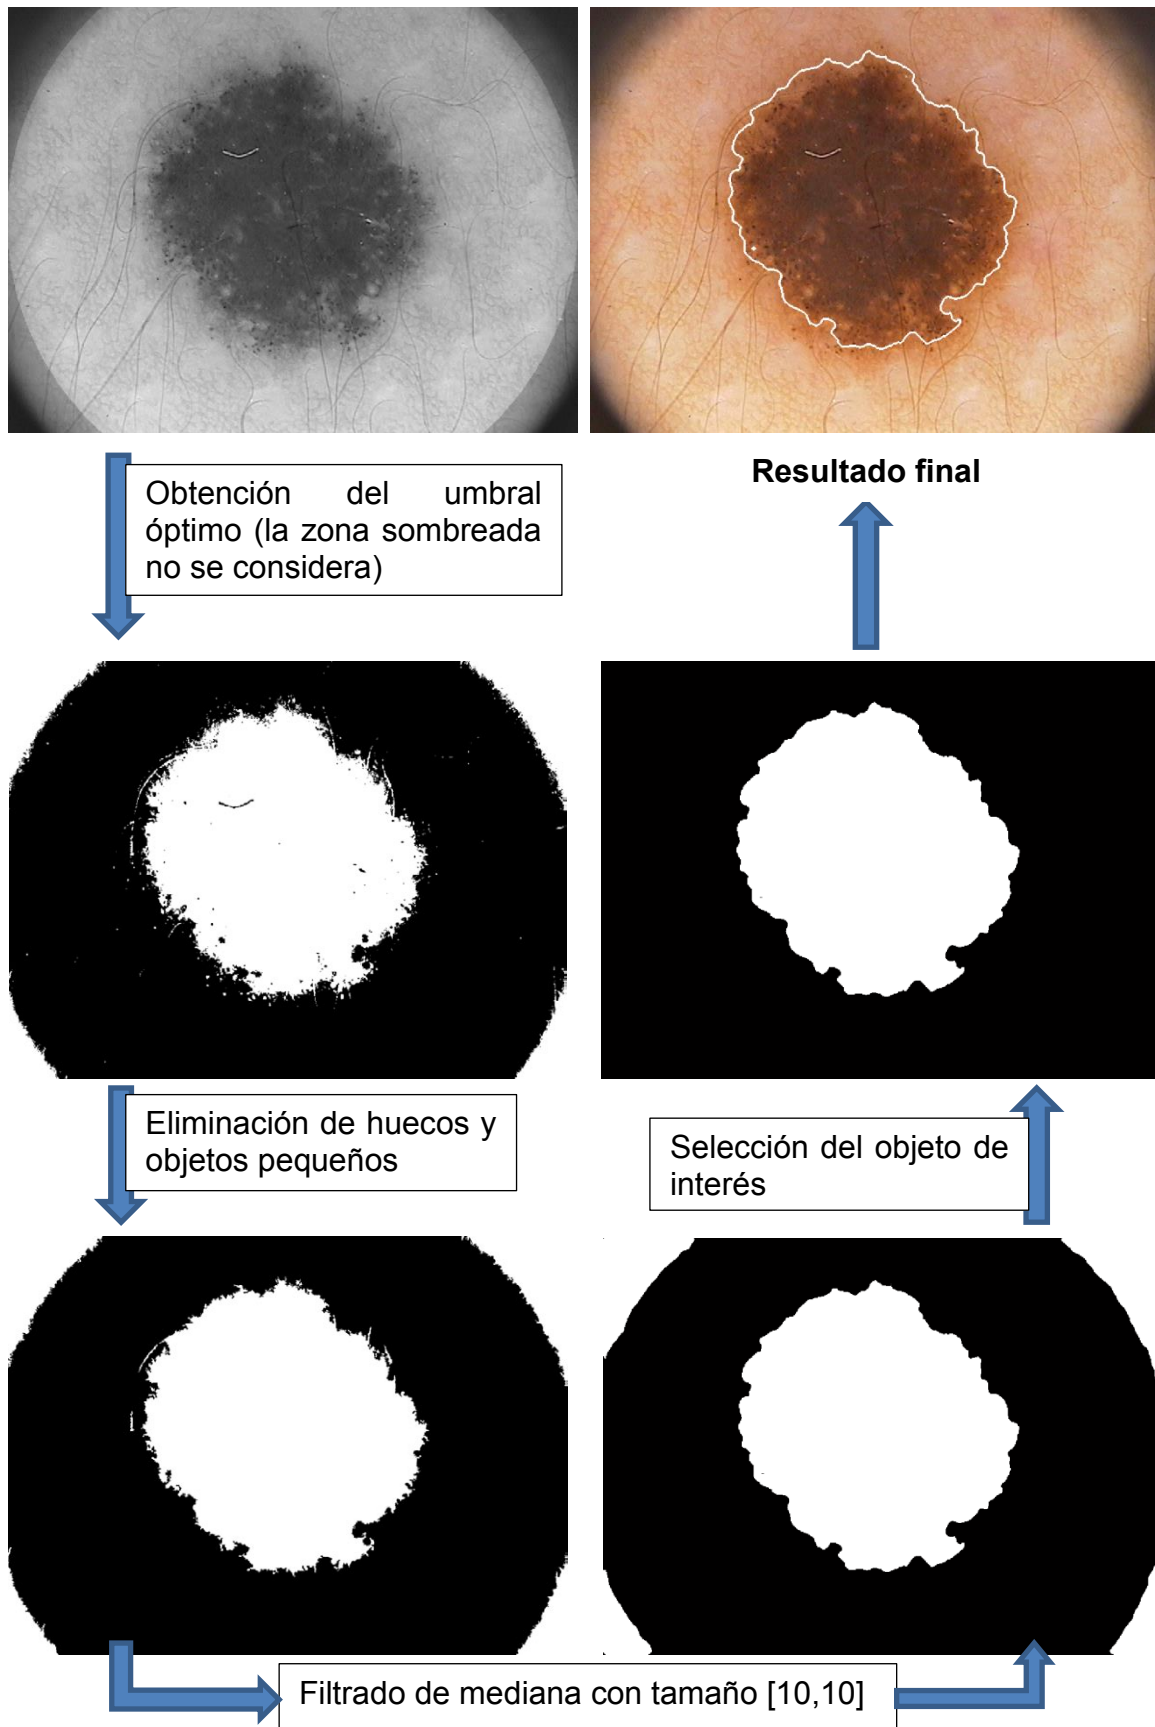


Figura 8-1 - Esquema segmentación

III. Descripción de la solución propuesta

Como se puede apreciar en la Figura 8-1, el método de segmentación descrito genera un buen resultado, comparable a la segmentación manual de la lesión (realizada por un experto), como se muestra en la Figura 8-2.




Figura 8-2 - Comparativa segmentación automática/manual

Este método de segmentación no está exento de algunas carencias. Por ejemplo, la lesión de la izquierda en la presenta lo que se conoce como un “área de regresión”, una despigmentación de la lesión en una zona determinada. En este caso concreto mediante operaciones morfológicas podría llegar a rellenarse la zona; pero en imágenes como la de la izquierda, la geometría de la lesión no lo permitiría de forma tan sencilla.




Figura 8-3 - Problemas de segmentación – zonas de regresión

Resulta evidente que en este caso, la solución pasa por segmentar la lesión en varias zonas diferenciadas, y agrupar las zonas correspondientes a la lesión. Se realizaron pruebas con dos técnicas diferentes:

- Umbralización con umbral múltiple. La función *grayscale* de Matlab realiza la misma función que el anteriormente utilizado *im2bw*, pero permite además especificar varios umbrales. De esta forma es posible, como se muestra en la Figura 8-4, segmentar la imagen en varios objetos y posteriormente unir los que formen parte de la lesión. La dificultad de este método radica en la necesidad de definir dichos umbrales.




Figura 8-4 - Segmentación por umbral múltiple

- Segmentación mediante técnicas de *clustering*. Se utilizó el algoritmo de k-medias para segmentar la imagen en k=3 objetos diferentes, para el ejemplo de la Figura 8-5.




Figura 8-5 - Segmentación por clustering (k-medias)

Otros problemas pueden deberse a la presencia de pelos en la imagen. Cuando estos no afectan al cálculo del umbral por presentar una intensidad similar a la de la lesión, el filtrado de mediana y las operaciones morfológicas pueden eliminar en cierta medida este problema, pero los bordes quedan deformados y requerirían procesado adicional. Un ejemplo es el de la Figura 8-6.



Figura 8-6 - Problemas de segmentación - pelos (1)

III. Descripción de la solución propuesta

Una forma de solucionar este problema es extraer en primer lugar los pelos para poder eliminarlos de la lesión. En [22] o [21] se proponen formas de realizar esta función, realizando los pelos mediante filtrado y eliminándolos mediante umbralización y operaciones morfológicas.

Dado que este trabajo no pretende centrarse exclusivamente en la segmentación, y que la presencia de vello no es un problema demasiado importante en la base de datos analizada, únicamente se utilizará de forma opcional el método ilustrado en la Figura 8-6. Dejando como mejora propuesta el desarrollo de un sistema más efectivo para la eliminación de vello.

9. Extracción de características

En este apartado se describen los algoritmos diseñados e implementados para la extracción de las características dermatológicas analizadas para la clasificación de la lesión.

Debido a las limitaciones de tiempo y a complejidad de algunas de estas tareas, se ha optado por estudiar las características más relevantes. En el resto de casos se empleará directamente la información proporcionada por la base de datos, que ha sido extraída y contrastada por especialistas dermatólogos mediante inspección visual. Se proporcionarán además herramientas para permitir el etiquetado manual de algunas de estas características por parte de usuarios expertos.

9.1. Asimetría

Para evaluar la asimetría de las lesiones, se optó por implementar el siguiente algoritmo.

1) En primer lugar se obtiene un conjunto de datos de la lesión utilizados posteriormente por el algoritmo. Para ello se desarrolló la función *getBorderData*, que obtiene y calcula las siguientes características y las almacena en la estructura *borderData*:

- Centroide: es el centro de simetría de la lesión, obtenido directamente de la máscara binaria correspondiente a la segmentación mediante la función *regionprops*.
- *Weighted centroid*: es el centro de simetría de la lesión ponderado por los valores de intensidad de los píxeles de la imagen convertida a escala de grises. Se calcula por tanto a partir de la máscara binaria y la imagen en escala de grises recortada por dicha máscara binaria.
- Coordenadas de los puntos del borde de la lesión: para ello se obtiene en primer lugar dicho borde a partir de la máscara binaria utilizando la función *bwperim*, y se obtienen las coordenadas de todos sus píxeles mediante la función *find*.
- Distancias euclidianas de los puntos del borde al *WeightedCentroid*.
- Ángulos de todos los puntos del borde respecto al *WeightedCentroid*, en grados y en el rango 0-360°.

Las coordenadas, distancias y ángulos de los puntos del borde se ordenaron en función del ángulo, para facilitar el resto del algoritmo.

2) Utilizando los vectores de distancia y ángulo almacenados en *borderData*, se estudian las diferencias entre las distancias medias al *WeightedCentroid* de todos los puntos del borde comprendidos en sectores circulares de apertura α y los situados en el ángulo opuesto. Estas diferencias se calculan mediante la ecuación 9-1, donde d_θ son las distancias de los puntos al *WeightedCentroid* para cada ángulo, α es el ángulo de apertura escogido y D_i son las diferencias de distancias medias obtenidas. En este caso se escogió $\alpha=15^\circ$, de forma que se divide la lesión en 24 sectores y se obtienen en total 12 diferencias D_i , por tanto $i \in [1,12]$

$$D_i = \sqrt{(\overline{d_\theta}|_{\theta+\alpha} - \overline{d_\theta}|_{\theta+\alpha+180})^2} \quad (9-1)$$

III. Descripción de la solución propuesta

- 3) Valores altos de D_i suponen un indicio de asimetría en la orientación en la que se producen. Por ello se compara este dato con un umbral y se marcan las regiones del borde que lo producen. La Figura 9-1 ilustra este proceso: los segmentos marcados en rojo presentan una diferencia de distancias medias respecto al *WeightedCentroid* que superan el umbral establecido. Se observa también representado el centroide con un marcador circular y el *WeightedCentroid* con una cruz.




Figura 9-1 - Estudio de asimetría

- 4) Se obtienen algunas propiedades adicionales de la lesión, que se detallan a continuación:
- Circunferencias exteriores e interiores a la lesión: centradas en el *WeightedCentroid*, y con radios la máxima y la mínima distancia borde-centroide, respectivamente. La relación entre dichos radios, $r_{circ} = \frac{\min(d_\theta)}{\max(d_\theta)}$, será máxima y de valor 1 si el borde es un círculo perfecto, y tenderá a 0 si presenta protuberancias o entrantes pronunciados.
 - Distancia entre el centroide y el *WeightedCentroid*, *centroidDist*, que será mínima si la distribución de la intensidad de los píxeles es uniforme respecto a la forma de ésta.
 - Indicador de si la lesión se encuentra completamente incluida en la imagen o si, por el contrario, existen partes no visibles.
 - Propiedad *eccentricity* (excentricidad) del objeto segmentado, obtenido mediante *regionprops*. Esta propiedad toma valores entre 1 si el objeto se asemeja a una línea recta, y 0 si es un círculo perfecto.
- 5) Finalmente, se asigna un valor de asimetría a la lesión en función de los datos obtenidos. Para ello se ha optado por diseñar el árbol de decisión de la Figura 9-2. $nOut$ representa el número de píxeles del borde que intersectan con los límites de la imagen, D_i son las diferencias de distancias para cada par de segmentos del borde y *asim* denota la puntuación de asimetría asignada.

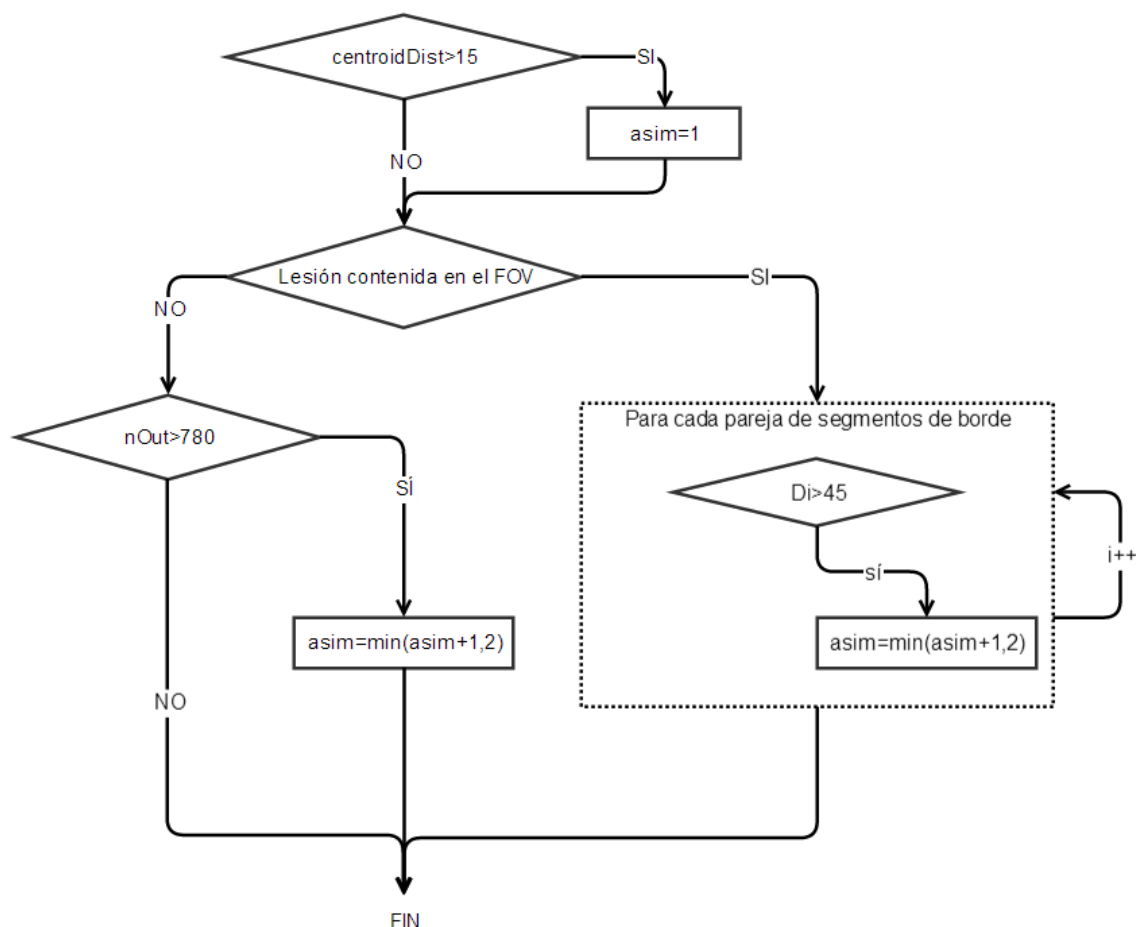


Figura 9-2 - Árbol de decisión – Asimetría

Se evaluó el rendimiento de este sistema, obteniéndose una precisión del 73% en la evaluación de la asimetría de las lesiones.

La eficacia de este módulo se ve condicionada por dos factores:

- El hecho de no disponer en algunos casos de la imagen completa de la lesión supone una pérdida de información que no puede ser recuperada o inferida a partir de la imagen disponible. Es un problema dependiente de las limitaciones de las tecnologías de captura de imagen y que escapa a los objetivos y alcance de este proyecto.
- La técnica empleada evalúa principalmente el contorno de la lesión, aunque la característica de distancia entre centroide y *WeightedCentroid* sí aporta alguna información sobre la distribución de su contenido. La evaluación de la simetría del contenido de la imagen representa un problema mucho más complejo. No obstante, se han consultado algunas fuentes que proponen soluciones a esta cuestión: en [30] se aborda de forma general la detección de simetría en imágenes en escala de grises; y [28] utiliza la propiedad de excentricidad de la máscara binaria y la proyección de la imagen sobre ejes principal y secundario, hallados previamente mediante análisis de componentes principales (PCA).

9.2. Bordes

III. Descripción de la solución propuesta

Para el estudio de la característica de borde se ha tomado como referencia la regla ABCD [10], que divide el contorno de la lesión en 8 segmentos y suma un punto a la puntuación de borde por cada segmento que presenta discontinuidad.

Se propone un algoritmo sencillo que busca discontinuidades en cada segmento, caracterizadas como cambios bruscos en la distancia al *WeightedCentroid*, que indican la presencia de protuberancias o entrantes en el contorno de la lesión.

Se utiliza la estructura de datos *borderData*, obtenida en de acuerdo con lo explicado en el apartado anterior. Esta estructura contiene las distancias de cada punto del borde al *WeightedCentroid*, así como el ángulo que forman con éste, referenciado al límite inferior de la imagen.

Para la búsqueda de discontinuidades, se procede de la siguiente forma:

- 1) Se divide el borde en ocho segmentos o regiones. Para ello se procede de forma similar a lo realizado en el estudio de la asimetría: se utilizan los valores de ángulo para obtener las coordenadas y distancias de los puntos del borde contenidos en cada uno de los 8 sectores circulares.
- 2) Para detectar saltos en las distancias de cada segmento, se obtiene el valor absoluto del gradiente del vector de distancias. Se suma un punto a la puntuación de borde por cada segmento en el cual el valor absoluto del gradiente de distancias supere al menos una vez un umbral definido.
- 3) Se incrementa en 1° el ángulo de partida θ_0 para la división en segmentos y se repiten los pasos 1 y 2, obteniendo una nueva puntuación de borde. Se itera de esta manera hasta que $\theta_0 = \frac{360^\circ}{8} = 45^\circ$. El objetivo es seleccionar la posición de las divisiones que devuelve la mínima puntuación de borde, evitando que discontinuidades muy próximas se consideren segmentos diferentes.

El esquema del algoritmo se muestra en la Figura 9-4. En la Figura 9-3 se muestran algunos ejemplos de la evaluación del borde de diversas lesiones de la base de datos.




Figura 9-3 – Ejemplos estudio del borde

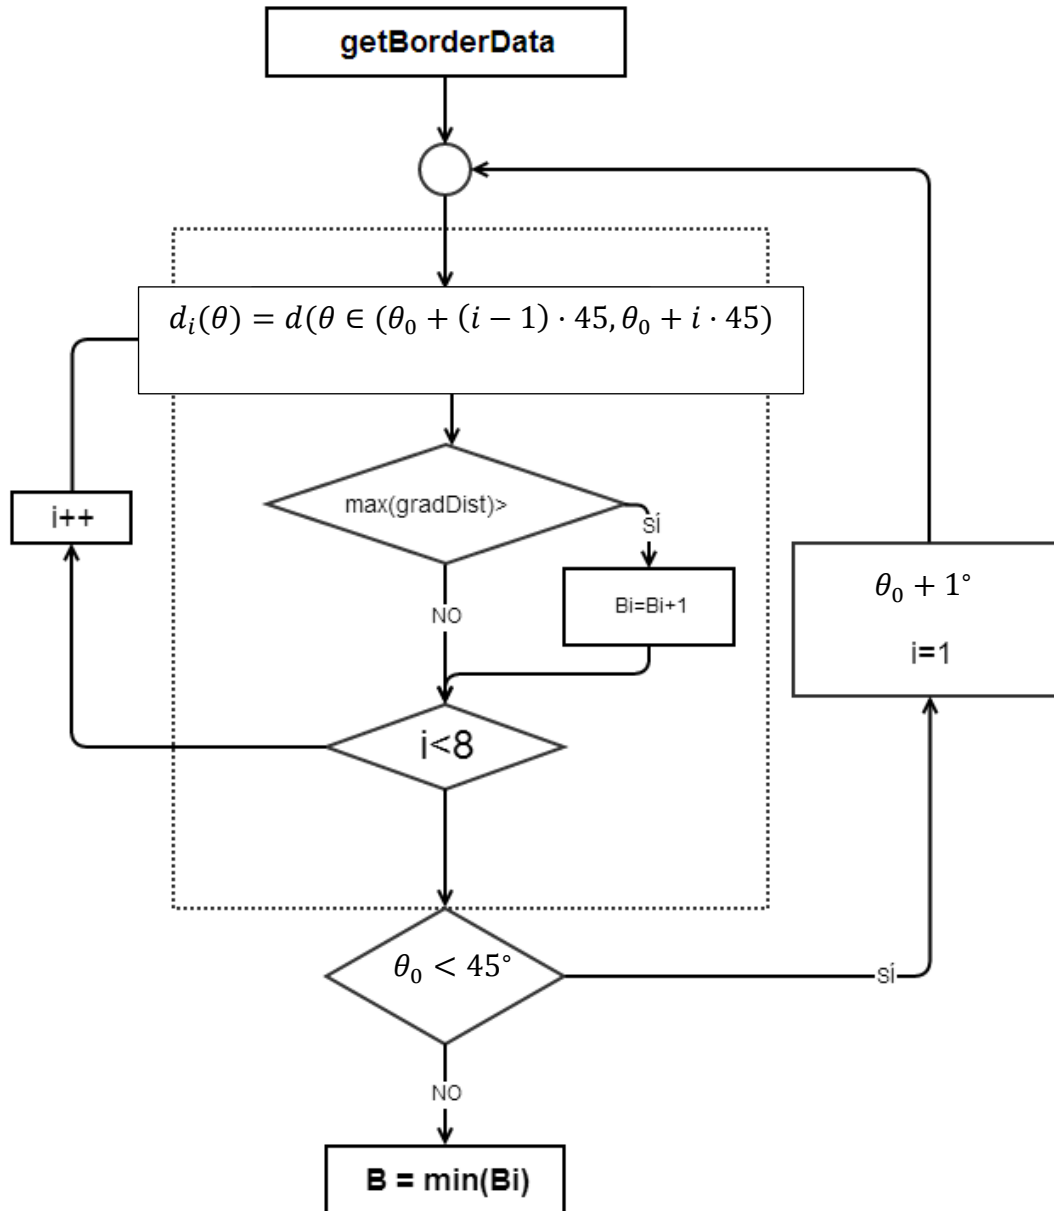


Figura 9-4 - Análisis del borde

La base de datos PH^2 no aporta información sobre la característica del borde de la lesión, por lo que no se ha podido contrastar la puntuación asignada por el algoritmo con la opinión de un dermatólogo experto. En cualquier caso, como hemos visto en la exposición de los métodos de diagnóstico, únicamente el método ABCD considera esta característica y su peso en el diagnóstico es mínimo.

III. Descripción de la solución propuesta

9.3. Colores

Como hemos visto en el apartado 2, la pigmentación de las lesiones melanocíticas puede aportar información relevante de cara a su diagnóstico.

En primer lugar es necesario decidir cuáles son las categorías de color que se desean distinguir en la imagen.

La regla ABCD [10] distingue entre seis colores diferentes: negro, marrón oscuro, marrón claro, rojo, azul grisáceo, y blanco. Los métodos de Menzies y CASH también utilizan estos colores, mientras que CHAOS & CLUES eleva el número de colores posibles a diez: negro, marrón oscuro, marrón claro, gris, azul, naranja, amarillo, blanco, rojo y morado (ver Figura 2-1).

No obstante, CHAOS & CLUES no considera directamente el número de colores presentes, por lo que se ha optado por tomar como referencia la clasificación de seis colores de la regla ABCD.

Para la identificación de estos colores se implementó un sistema muy simple pero que como veremos, proporciona unos resultados aceptables al aplicarse a las imágenes de la base de datos *PH²*. El método en cuestión se describe a continuación:

- 1) En primer lugar se obtienen cuatro imágenes diferentes a partir de la imagen original en color: estas imágenes son *iR*, *iG*, *iB* –correspondientes a los canales rojo, verde y azul de la imagen original, respectivamente- y *gray*, el resultado de convertir la imagen a escala de grises.
- 2) A continuación se obtienen seis máscaras binarias correspondientes a los seis colores buscados. Cada una de ellas se obtiene combinando una serie de condiciones basadas en las propiedades de las imágenes *iR*, *iG*, *iB* y *gray*.
- 3) Las máscaras resultantes son tratadas mediante operaciones morfológicas de dilatación, eliminación de elementos de pequeño tamaño y rellenado de huecos, terminando con un filtrado de mediana para suavizar la máscara resultante.
- 4) Se calcula el área total de cada una de las seis máscaras, así como el porcentaje que representa del área total de la lesión.
- 5) Finalmente, se comparan los porcentajes de área (P_{area_i}) obtenidos con unos porcentajes umbral definidos para cada color (U_i), y se marcan como presentes aquellos para los que dicha condición se cumple. La decisión de no utilizar un umbral común a todos los colores se justifica en que los colores menos habituales, como el rojo o el negro, no suelen cubrir un gran área aun cuando están presentes en la lesión. Por ello se selecciona un umbral menor para estos colores.

$$C_i = \begin{cases} \text{Presente} & \text{si } P_{area_i}(\%) \geq U_i(\%) \\ \text{Ausente} & \text{si } P_{area_i}(\%) < U_i(\%) \end{cases} \quad (9-2)$$

Se implementó una función para representar de forma aproximada las regiones de cada color sobre la imagen original en color.

9.4. Diferencias estructurales

9.4.1. Retículo pigmentado

La presencia de una red de pigmentación atípica puede ser indicativa de la malignidad de una lesión. La Figura 9-5 muestra un ejemplo de melanoma en el que este tipo de estructura está presente.



Figura 9-5 - Ejemplo de melanoma con retículo pigmentado

Como se puede observar en la imagen, esta estructura se caracteriza por una fina red con huecos de pigmentación más clara.

Varios de las referencias consultadas, como [24], [32] o [22], describen formas de extraer esta característica. A continuación se describe la solución implementada, basada en parte en el método estructural propuesto por [24], y que dividiremos en tres fases:

1. Extracción del retículo pigmentado mediante realzado de bordes y umbralización.
 - 1.1. En primer lugar, se convierte la imagen original en color a escala de grises.
 - 1.2. Se obtiene una copia de dicha imagen, a la que se aplica un filtrado de mediana mediante la instrucción *medfilt2* de Matlab.
 - 1.3. Se combinan las dos imágenes de acuerdo con la ecuación 9-3, en la que I_{gray} es la imagen en escala de grises y I_{median} es la imagen resultante del filtrado de mediana.

$$I_{comb} = I_{median} - I_{gray} \quad (9-3)$$

III. Descripción de la solución propuesta

1.4. Se obtiene la máscara binaria mediante umbralización.

1.5. Se aplican operaciones morfológicas de cierre y se eliminan las estructuras de pequeño tamaño. En la Figura 9-6 se muestra el resultado de estas operaciones, tras procesar la imagen de la Figura 9-5.




Figura 9-6 - Extracción del retículo pigmentado

2. Segmentación de las zonas atípicas. Si bien el procedimiento anterior permite extraer con bastante eficacia máscara binaria con la textura reticular, es necesario un procesamiento posterior para eliminar aquellas partes de la máscara que puedan no corresponderse con la red pigmentada, por ejemplo arrugas o pelos. Para ello se aplica procesamiento local a los píxeles de la imagen en escala de grises en las posiciones de la máscara, evaluando las siguientes condiciones:

2.1. Los píxeles con un valor de luminosidad muy bajo se eliminan de la máscara, ya que habitualmente indican la presencia de vello en la imagen.

2.2. Se compara el valor de luminosidad de cada píxel con la mediana de los píxeles cercanos en un radio de 4 píxeles, que debe tener un valor mayor por las características de esta estructura. En la Figura 9-7 se muestra el resultado.




Figura 9-7 - Post-procesado del retículo pigmentado

3. Decisión sobre la presencia de patrón reticular atípico. Se realiza en base a la relación entre el área de las zonas con patrón reticular y el área total de la lesión.
 - 3.1. Para calcular el área de las zonas con red pigmentada, en primer lugar se procesa la máscara binaria aplicando rellenado de huecos, dilatación y el operador *majority* para suavizar el contorno de la región resultante. El resultado se muestra en la Figura 9-8




Figura 9-8 - Segmentación de las zonas con patrón reticular

- 3.2. Se utiliza la función *regionprops* para obtener el área de la red pigmentada.
 - 3.3. Se obtiene el valor medio de la intensidad de los píxeles de la red pigmentada.

III. Descripción de la solución propuesta

El método descrito segmenta de manera bastante efectiva esta estructura. No obstante, clasificarla como “típica” o “atípica” constituye un problema más complejo.

En [35] se define el retículo pigmentado atípico como aquel que presenta trazos gruesos o orificios de diferentes tamaños. También es signo de atipia el denominado retículo pigmentado negativo, en el que las líneas tienen una pigmentación más clara que los orificios.

Tomando estas consideraciones como referencia, se plantean las siguientes opciones para clasificar la red pigmentada:

- 1) Para evaluar el grosor de las líneas, aplicamos la operación morfológica de erosión a la red pigmentada, de forma que se eliminarán todos los píxeles de la máscara correspondientes a trazos finos, quedando únicamente los que tengan un grosor mínimo.
- 2) Para estudiar los orificios, en primer lugar obtenemos la máscara binaria correspondiente. Para ello obtenemos aplicamos la operación de rellenado de huecos a la máscara binaria de la red pigmentada y le restamos la máscara original, de forma que quedan únicamente los objetos correspondientes a los huecos. Calculamos entonces el área y la intensidad media de cada hueco, y obtenemos las siguientes características:
 - a. Media de las áreas e intensidades medias de los huecos.
 - b. Desviación típica las de áreas e intensidades medias de los huecos.

La detección de redes pigmentadas negativas no ha sido implementada debido a la ausencia de ejemplos claros de esta característica en la base de datos. No obstante, un procedimiento posible sería una variación del procedimiento explicado en el punto 2.2, escogiendo en este caso los píxeles para los que el valor de la luminosidad es mayor que la imagen producto del filtrado de mediana. Posteriormente sería necesario evaluar el tamaño de los huecos relativo al área de la lesión, para evitar confundir con redes pigmentadas negativas la presencia de manchas o glóbulos, otra característica dermatoscópica.

En cuanto a la evaluación de la red pigmentada en base a las características de las zonas contiguas, no se observaron características suficientemente sólidas como para determinar a partir de ello el carácter atípico de la red pigmentada. Se propone un estudio más profundo de los criterios dermatológicos en el análisis de esta estructura, y la búsqueda de características más discriminantes, así como un método más seguro para la segmentación de los huecos de la red pigmentada.

Se ha optado finalmente por clasificar esta estructura en base a la intensidad media de los píxeles y el área de la red pigmentada, de acuerdo con el esquema de la Figura 9-9.

Este método presenta una alta sensibilidad al detectar la mayoría de las redes pigmentadas marcadas como atípicas en los datos de *ground truth*. La especificidad referida a esta característica baja, pero dada la estructura de los algoritmos de diagnóstico implementados, esta baja especificidad en el estudio de la red pigmentada no afecta de forma importante a la especificidad en el diagnóstico, por lo que se considera una solución satisfactoria.

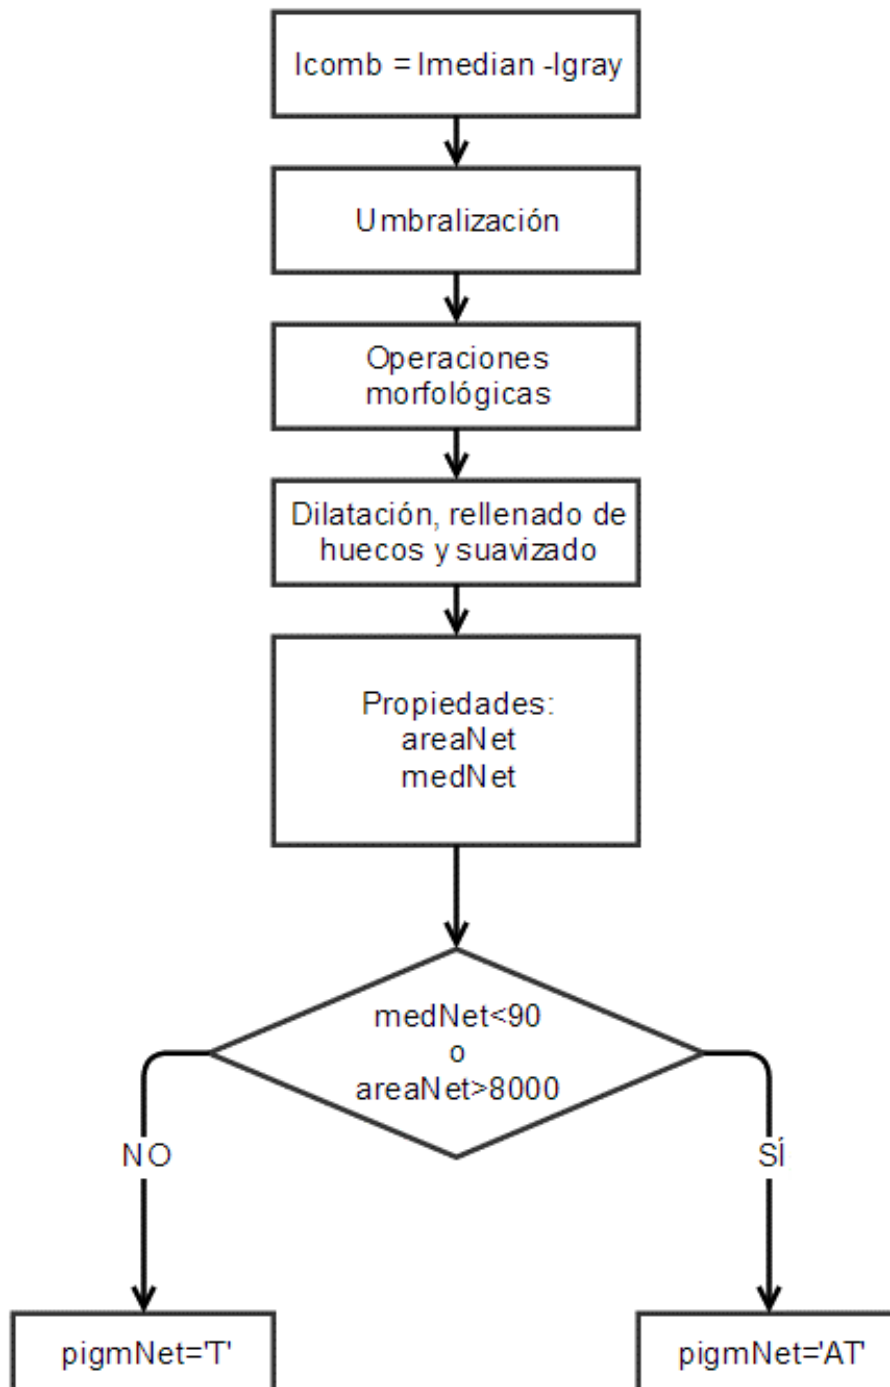


Figura 9-9 - Esquema detección de red pigmentada

9.5. Velo azul-blanquecino

Como hemos visto anteriormente, la presencia de zonas con pigmentación azulada y clara en la lesión habitualmente indican la presencia de melanina en la dermis y es una característica que presenta gran especificidad en las lesiones de tipo melanoma.

Para detectar la presencia de esta característica en las imágenes analizadas se ha optado por el siguiente procedimiento:

En primer lugar se carga la imagen en color, se separa por canales (R, G y B) y se obtiene una nueva combinación de colores de acuerdo con la ecuación.

$$g(x, y) = C_B \cdot f_B(x, y) - C_G \cdot f_G(x, y) - C_R \cdot f_R(x, y)$$

Donde $f_R(x, y)$, $f_G(x, y)$, y $f_B(x, y)$ son los canales RGB de la imagen, y C_R, C_G, C_B son coeficientes. Con esto se obtiene una versión de la imagen en la que las estructuras azuladas, de estar presentes, tienen un mayor valor de intensidad.

Posteriormente se aplica un filtrado de mediana para suavizar la imagen, y a continuación se aplica un umbral T para diferenciar las estructuras de tonalidad azulada. Se emplean operaciones morfológicas para mejorar la visualización de la máscara resultante.

Por último se obtiene el área de la zona segmentada y se compara con el área total de la lesión; si la supera en un porcentaje, se marca la característica como "P" (presente), en caso contrario como "A" (ausente).

El esquema general del algoritmo se representa en la Figura 9-10

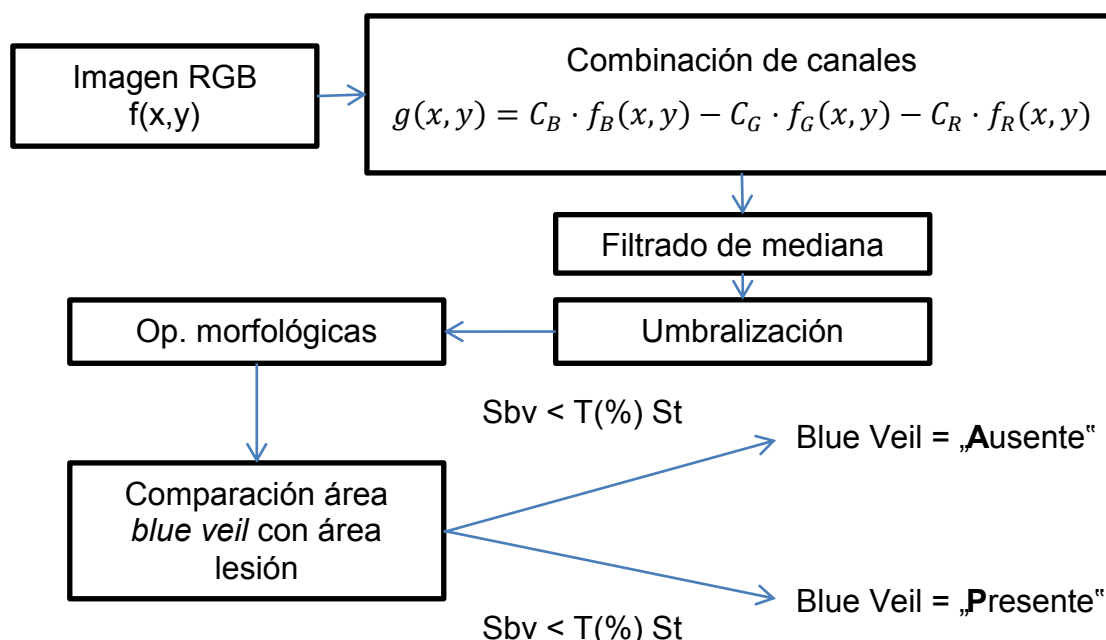


Figura 9-10 - Diagrama de bloques "Blue Veil"

En la Figura 9-11 se muestra el resultado para una pareja de imágenes de lesiones con *blue veil* presente.




Figura 9-11 - Detección de “Blue Veil”

Los valores óptimos escogidos para los coeficientes y el umbral se recogen en la Tabla 9-1.

Parámetro	C_R	C_G	C_B	T	% de área
Valor	-1.2	1	1.3	50	5%

Tabla 9-1 – Valores detección de velo azul-blanquecino

Se evaluó la detección del velo azul-blanquecino respecto a los datos de *ground truth*, obteniéndose con una precisión del **87%** para los parámetros de configuración escogidos.

9.5.1. Manchas y glóbulos, proyecciones radiales (*streaks*) y zonas de regresión

La detección automática de estas tres características no ha sido implementada en este trabajo debido a las limitaciones de tiempo.

El etiquetado de estas características disponible en la base de datos *PH²* ha sido realizado mediante inspección visual por dermatólogos expertos [34], por lo que se ha escogido como *gold standard* para la evaluación del sistema.

Por ello, como alternativa a la detección automática de estas características, se ha decidido incluir en el programa una opción para el etiquetado manual de estas características, que debería ser realizada por un experto. Desde la interfaz principal de la aplicación se puede indicar si se quiere utilizar esta opción.

Esta herramienta permite marcar cada una de las tres características como presentes o ausentes y, además marcar sobre la imagen las regiones de interés de cada una de ellas, añadir nuevas o resetear la selección en caso de que se haya cometido algún error.

III. Descripción de la solución propuesta




Figura 9-12 - Herramienta de etiquetado de estructuras (imagen con *dots* y áreas de regresión)



Figura 9-13 - Herramienta de etiquetado de estructuras (imagen con *streaks*)

10. Clasificación automática de las lesiones

Para la clasificación automática de las lesiones estudiadas se optó por implementar algunos de los algoritmos de diagnóstico explicados en el apartado 2.

Esta decisión se fundamenta en el hecho de que dichos algoritmos comparten algunas características de entrada comunes, lo que facilita su implementación y posterior comparación.

En concreto se han implementado los algoritmos ABCD, 7 *points-checklist*, Menzies y CHAOS & CLUES.

Dado que estos algoritmos no definen claramente la frontera entre “nevus” y “nevus atípico”, se han agrupado estas dos clases bajo una sola, a la que nos referiremos de aquí en adelante como “lesión benigna”. Por tanto, las lesiones serán clasificadas entre “lesiones benignas” y “melanomas”. Esta consideración se tendrá en cuenta también a la hora de evaluar los resultados, como se verá en el apartado 0.

Se desarrolló la función *diagnose* para clasificar las lesiones mediante el método de diagnóstico escogido. Esta función recibe como entrada la estructura de datos *myData*, que contiene los siguientes campos:

myData.asim: puntuación de asimetría (0, 1, o 2)

myData.borders: puntuación de borde (de 0 a 8)

myData.colors: lista de colores detectados

myData.pigmNet: presencia de red pigmentada típica („T”) o atípica („AT”)

myData.blueVeil: presencia („P”) o ausencia („A”) de velo azul-blanquecino

myData.dotsGlobs: presencia de puntos y glóbulos típicos („T”) o atípicos („AT”)

myData.streaks: presencia („P”) o ausencia („A”) de proyecciones radiales

myData.regression: presencia („P”) o ausencia („A”) de zonas de regresión

Adicionalmente se calcularon los valores *nColors* (número de colores en *myData.colors*) y *nStructures* (número de características estructurales presentes o atípicas).

El segundo parámetro de entrada, *method*, especifica el método de diagnóstico a emplear.

A continuación se muestran los esquemas de cada uno de los métodos e clasificación implementados, que se detallaron en el apartado 2.

III. Descripción de la solución propuesta

Método ABCD




Figura 10-1 – Implementación método ABCD

Método de Menzies




Figura 10-2 - Implementación regla de Menzies

7-point checklist

Nótese que se trata de una versión ligeramente modificada del método original, no evaluándose en este caso una séptima característica de presencia de “patrones vasculares atípicos”, debido a que ninguna de las imágenes de la base de datos PH^2 presentaba dicha característica.

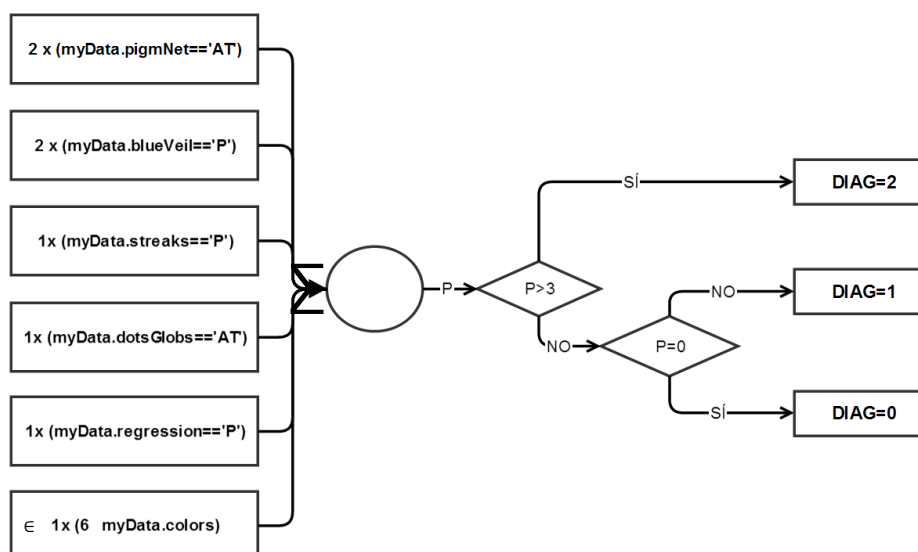


Figura 10-3 - Implementación método 7-point checklist

CHAOS & CLUES




Figura 10-4 - Implementación regla CHAOS & CLUES

11. Evaluación de los resultados

La evaluación de resultados resulta fundamental en el desarrollo de un sistema de clasificación automática. Por ello se ha incorporado al programa una opción que permite realizar pruebas con todas las imágenes de la base de datos y obtener estadísticas que permitan analizar el funcionamiento del sistema.

Este modo de trabajo, al que se puede acceder directamente a través de la interfaz de usuario, procesa una por una todas las imágenes y compara los resultados obtenidos con la información presente en la base de datos, calculando los siguientes parámetros:

- Porcentajes de TP, FP, TN y FN en el diagnóstico de la lesión. Como se ha explicado en el apartado 0, se han agrupado como “lesión benigna” los elementos de la base de datos con diagnósticos 0 y 1. Por lo que la evaluación de TP, FP, TN y FN se hace de acuerdo a la Tabla 11-1

		Diagnóstico obtenido		
		0	1	2
Ground Truth	0	TN	TN	FP
	1	TN	TN	FP
	2	FN	FN	TP

Tabla 11-1 – Tabla para evaluar el diagnóstico

Como se ha mencionado previamente, el significado de las puntuaciones es:

- 0: nevus.
- 1: nevus atípico.
- 2: melanoma.
- Índices de sensibilidad, especificidad y precisión, de acuerdo con lo explicado en el apartado 5. En el apartado de resultados (pág. 63) se muestran los índices obtenidos para las pruebas efectuadas con cada uno de los métodos de diagnóstico.
- Porcentajes de acierto en la evaluación de cada una de las características extraídas de la lesión. Exceptuando la característica “borde”, de la cual no existe información en la base de datos. Estos últimos porcentajes resultaron de gran utilidad durante el desarrollo de los algoritmos de extracción de características, facilitando la elección de los parámetros adecuados para maximizar los porcentajes de acierto.

IV. Resultados, conclusiones y futuras líneas de investigación

12. Resultados

Se utilizó el módulo desarrollado para el procesado en lote de la base de datos para evaluar la efectividad del sistema para cada uno de los métodos de diagnóstico implementados. Las pruebas se realizaron en las siguientes condiciones:

- Se procesaron las 200 imágenes de la base de datos PH^2 .
- Se utilizó la segmentación proporcionada por la base de datos, a fin de evitar resultados incorrectos debido a la ausencia de pre-procesado para eliminar los pelos.
- No se evaluó la característica de borde, debido a que no existía información de *ground truth* acerca de esta característica. Sí se tuvo en cuenta para el diagnóstico mediante la regla ABCD, que es la única que valora esta característica.
- Se utilizaron las características de manchas y glóbulos, *streaks* y áreas de regresión proporcionadas por la base de datos, al no haberse implementado de forma automática. La herramienta de etiquetado manual debería ser utilizada solo por especialistas en dermatología.

La Tabla 12-1 muestra los resultados obtenidos, que se analizarán posteriormente.

Método	ABCD	Menzies	7-point checklist	CASH	CHAOS & CLUES
Sensibilidad	50.00%	72.50%	80.00%	25.00%	90.00%
Especificidad	97.50%	85.00%	76.25%	98.12%	77.50%
Precisión	88.00%	82.50%	77.00%	83.50%	80.00%

Tabla 12-1 – Resultados diagnóstico automático

A fin de observar el rendimiento de los distintos métodos de diagnóstico, se realizaron pruebas utilizando directamente los datos proporcionados por la base de datos, obteniendo los siguientes resultados.

Método	ABCD	Menzies	7-point checklist	CASH	CHAOS & CLUES
Sensibilidad	72.50%	87.50%	80.00%	52.50%	87.50%
Especificidad	96.25%	76.87%	88.75%	98.75%	71.25%
Precisión	91.50%	79.00%	83.50%	89.50%	74.50%

Tabla 12-2 – Resultados diagnóstico automático utilizando características de la base de datos

Análisis de los resultados

En primer lugar se desea analizar la efectividad de los distintos métodos en base a las características de entrada disponibles. Por ello centraremos el estudio en los resultados mostrados en la Tabla 12-2, por estar basados en el *gold standard* de las características de las lesiones.

A la vista de dichos resultados, podemos observar que la regla ABCD proporciona la mayor precisión, aunque a costa de una baja sensibilidad. Las reglas de Menzies y CHAOS & CLUES proporcionan la mayor sensibilidad, alcanzando el 87%, aunque su especificidad es menor, lo que es señal de mayores tasas de falsos positivos.

El método de *7-point checklist* presenta los resultados más equilibrados. Por último, llama la atención la baja sensibilidad del método CASH, poco más del 50%.

En cuanto a los resultados obtenidos a partir de las características extraídas por los algoritmos desarrollados, podemos observar que no se alejan demasiado en términos de precisión de los obtenidos anteriormente. Se observa una caída en la sensibilidad en algunos métodos, aunque el método CHAOS & CLUES muestra un aumento de sensibilidad.

Es conveniente valorar estos resultados en relación a la base de datos utilizada. La base de datos *PH²* contiene únicamente 40 muestras de melanoma, representando un 20% del total de las imágenes, por lo que cada falso negativo afecta en mayor medida a la sensibilidad de lo que lo hacen los falsos positivos a la especificidad. Por otro lado, las condiciones de algunas de las imágenes correspondientes a melanomas dificultan la correcta extracción de algunas de sus características.

Con todo, podemos concluir que los resultados obtenidos se mantienen dentro de unos márgenes aceptables en relación a los proporcionados por la información de *ground truth* aplicando los métodos de diagnóstico propuestos.

En el siguiente apartado se referirán las conclusiones extraídas de este trabajo y se propondrán posibles líneas de mejora del sistema implementado.

13. Conclusiones

En este trabajo se ha realizado un estudio extenso del estado del arte de la dermatoscopia y las técnicas de procesamiento de imagen aplicadas al análisis de lesiones cutáneas; así como de los métodos basados en análisis de patrones para el diagnóstico del melanoma.

Se ha implementado un método de segmentación de las lesiones basado en umbralización y se han planteado soluciones a casos de segmentación más complejos -como son la presencia de vello y las lesiones con pigmentación múltiple- mediante umbralización múltiple o el *clustering* mediante k-medias.

Se han desarrollado algoritmos para extraer características relevantes de las lesiones, tales como su asimetría, cambios abruptos en el borde o presencia de varios colores; así como métodos para detectar la presencia de estructuras atípicas tales como la red pigmentada o el velo azul-blanquecino. También se ha desarrollado una herramienta destinada a facilitar el etiquetado manual de otras características estructurales relevantes, de forma visual e integrada en el software de análisis.

En base a las características obtenidas, se ha implementado una funcionalidad que aplica los métodos de diagnóstico más habituales –reglas ABCD, Menzies, *7-point checklist* o CHAOS & CLUES- para clasificar las imágenes entre lesiones benignas y lesiones sospechosas de ser melanoma.

Se han realizado pruebas sobre la base de datos de imágenes dermatoscópicas *PH²*, evaluando la especificidad, sensibilidad y precisión del sistema de clasificación.

Durante el desarrollo del proyecto se han extraído una serie de conclusiones acerca del estado del arte de la visión artificial aplicada al estudio del melanoma, así como las actuales dificultades y líneas de investigación en este campo.

- La segmentación de las lesiones, en general, es un procedimiento sencillo cuando éstas corresponden a nevus benignos o de baja atipia, caracterizados por contornos ovalados y lisos y por una pigmentación más o menos homogénea y fácilmente distinguible de la piel sana circundante. Por otro lado, las lesiones malignas a menudo presentan formas complejas y una pigmentación heterogénea y distribuida de forma irregular. Además, estas lesiones a menudo tienen mayor tamaño, lo que unido a las limitaciones de los dispositivos de captura, provoca que las imágenes correspondientes representen estas lesiones de forma incompleta o con ruido o iluminación no uniforme.
- Varias de las referencias consultadas, así como este trabajo, se basan en los métodos de diagnóstico empleados por los dermatólogos para diseñar algoritmos que faciliten la segmentación de las lesiones y la detección de las estructuras atípicas. Si bien éste es un punto de partida válido a la hora de describir las características de las lesiones malignas, el objetivo de estas aplicaciones no suele ir más allá de proporcionar una clasificación equiparable a la que realiza un dermatólogo mediante inspección visual.

Esto puede tener aplicaciones muy valiosas, como puedan ser por ejemplo el desarrollo de aplicaciones móviles que permitan al público general analizar sus lesiones cutáneas y acudir al dermatólogo en caso de encontrar características anómalas.

- Durante el estudio del estado del arte se encontraron también trabajos que enfocan el problema desde una perspectiva diferente: el desarrollo de técnicas que permitan extraer

IV. Resultados, conclusiones y futuras líneas de investigación

otro tipo de características de la lesión que puedan proporcionar información adicional al dermatólogo a la hora de tomar una decisión. Existen por ejemplo desarrollos en captura de imagen hiperespectral [36] que permiten un análisis más detallado de las estructuras de la piel, o técnicas que utilizan la fotoacústica para detectar presencia de células de melanoma en la sangre. Estos avances en tecnologías de captura crean la necesidad de investigar nuevos sistemas de clasificación que permitan detectar con mayor precisión el melanoma.

- Se ha puesto en relieve la importancia del diagnóstico temprano del melanoma, debido a su capacidad de generar metástasis. La cirugía realizada en las primeras etapas del desarrollo del cáncer asegura altos índices de supervivencia en el paciente.

Los algoritmos de clasificación desarrollados a menudo se centran en clasificar entre lesiones benignas o atípicas, y melanoma. Sin embargo, muchas las lesiones de la última categoría que se muestran en las bases de datos se corresponden a melanomas en estados relativamente avanzados y habitualmente serían detectados a simple vista por un dermatólogo.

Un estudio más profundo de las lesiones clasificadas como atípicas, podría permitir clasificarlas antes como melanomas. En particular, la observación de la evolución de estas lesiones atípicas a lo largo del tiempo facilitaría la detección de cambios menos evidentes que puedan alertar de la aparición del melanoma. Los sistemas de dermatoscopia digital modernos comienzan a tomarse en serio estas cuestiones, permitiendo registrar las lesiones cada cierto período de tiempo, así como detectar la aparición de lesiones nuevas en pacientes con muchos lunares.

Surge así la necesidad de disponer de bases de datos que contengan imágenes de las lesiones a lo largo del tiempo, y que puedan utilizarse como *ground truth* para la investigación y el desarrollo de este tipo de algoritmos.

14. Mejoras y futuras líneas de investigación

A lo largo de este trabajo se ha hecho referencia a ciertas limitaciones o posibles mejoras en los métodos implementados, que se resumen a continuación:

- En cuanto a la segmentación de las lesiones, se destaca la necesidad de implementar un método para eliminar de forma efectiva el ruido (vello y manchas causadas por la interfase líquida utilizada junto al instrumento óptico).
- La detección de diferentes colores es un problema complejo, debido a la definición poco precisa de los colores de interés, su escaso rango dinámico y la necesidad de considerar el color en referencia a la pigmentación tanto de la lesión como de la piel sana circundante. Se sugiere la posibilidad de estudiar la variabilidad en el color desde un enfoque diferente, y estudiar la relación entre dichos colores y estructuras concretas de la lesión a fin de discriminar mejor las regiones de interés.
- Sería interesante profundizar en el estudio de la red pigmentada con el fin de determinar con mayor precisión qué características se consideran a la hora de señalarlas como atípicas. Así como estudiar su relación con la característica de las proyecciones radiales, o *streaks*, que en ocasiones aparecen entrelazadas con la propia red pigmentada.
- Una alternativa interesante sería el desarrollo de un algoritmo de clasificación que trabajase con un conjunto de características no necesariamente similar al de los métodos clínicos; sería posible en este caso utilizar características que no son observables mediante inspección visual, pero que pueden aportar información relevante para el diagnóstico.

Anexo I – Referencia de funciones implementadas

- **Main_GUI**: código de la interfaz gráfica de usuario.
- **evaluateDiag**: compara el diagnóstico obtenido con el de *ground truth* y devuelve TP, TN, FP o FN
- **batchProcess**: procesa el conjunto de archivos de la base de datos en base a la configuración elegida.
- **diagnose**: clasifica la lesión en base al método de diagnóstico especificado
- **getBorderData**: obtiene las coordenadas, distancias y ángulos respecto al centroide del contorno de una máscara binaria
- **getGTdata**: obtiene los datos de *ground truth* de una imagen concreta
- **processDbPH2**: copia los archivos de la base de datos PH2 al directorio de trabajo y extrae del fichero original los datos de *ground truth* para guardarlos en el fichero dbgt.mat
- **features**: extrae las características de la lesión, llamando a las subfunciones apropiadas.
 - **getFeatAsymmetry**
 - **getFeatBorder**
 - **getFeatColors**
 - **getFeatBlueVeil**
 - **getFeatPigmNet**
 - **ManualStructures**
- **segmentation**: segmenta la lesión, devolviendo la máscara binaria
- **showResult**: representa la imagen junto a las marcas y regiones procesadas, y proporciona un *handler* para permitir activar o desactivar la visualización de estas.
- **resStatistics**: analiza los resultados obtenidos por *batchProcess* y lanza la ventana *Statistics*, en la que se muestran las tasas de TP, TN, FP, FN, sensibilidad, especificidad y precisión para cada uno de los métodos de diagnóstico.
- **sbar**: facilita la utilización de la función externa *statusbar*, utilizada para mostrar una barra de progreso en la interfaz de usuario que indique el estado de las operaciones.
- **ManualStructures**: interfaz para el etiquetado manual de las características de puntos y glóbulos, proyecciones radiales (*streaks*) y zonas de regresión

Algunas de estas funciones se encuentran en el directorio *utils*, que es importado automáticamente al *path* de Matlab al cargar el programa.

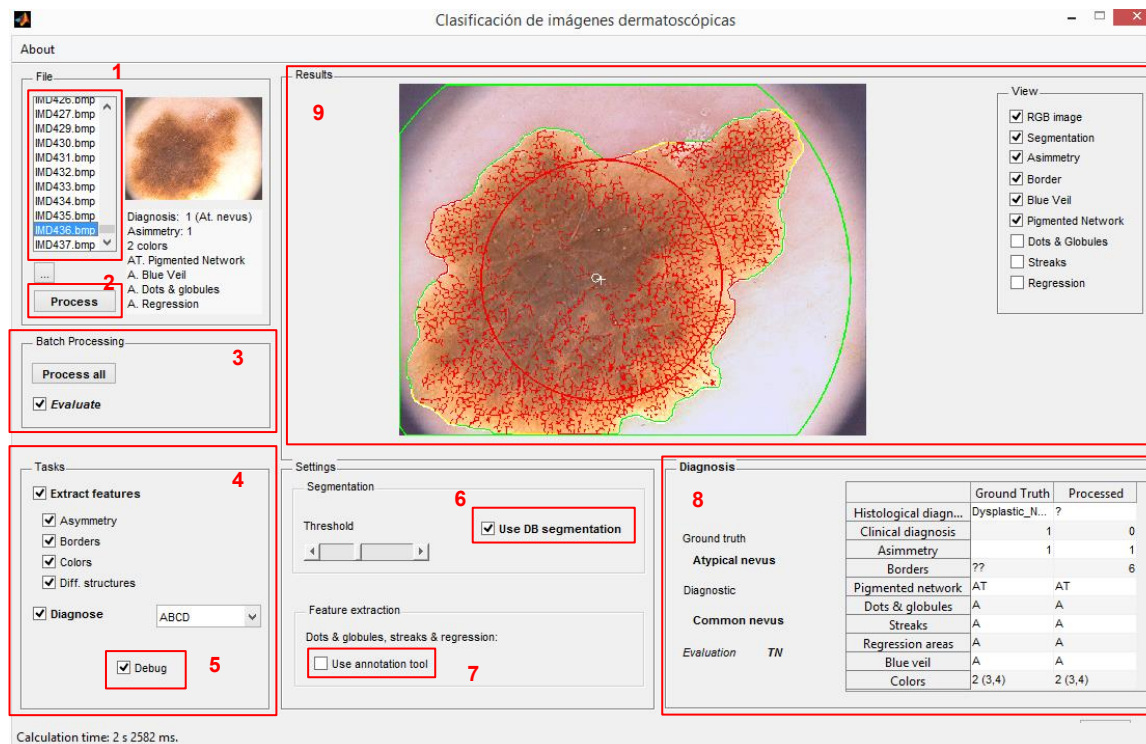
Se empleó la función externa ***statusbar***, que permite añadir una barra de estado a la interfaz gráfica. Esta función está disponible en:

<http://www.mathworks.com/matlabcentral/fileexchange/14773-statusbar>,

y se ha incluido en la carpeta *utils*.

Anexo II – Descripción de los componentes de la interfaz de usuario

La figura muestra la interfaz de usuario desarrollada, sobre la que se marcan los controles principales. La utilidad y modo de uso de estos controles se explica a continuación.



- 1) Lista de archivos en la carpeta *PH2_database* de imágenes dermatoscópicas. Al seleccionar un elemento se muestra una miniatura de la imagen junto con información de *ground truth* de esta. Al presionar *enter* en el teclado la imagen seleccionada en ese momento se procesa.
- 2) Botón procesar. Carga la imagen seleccionada y la procesa de acuerdo con la configuración escogida.
- 3) Bloque de procesado en lote. *Process all* inicia un bucle en el que se procesan de forma sucesiva todas las imágenes del directorio de la base de datos. Los datos resultantes se almacenan en el archivo *results.mat* que posteriormente es procesado por el script *resStatistics* para devolver la evaluación de resultados. El cuadro de texto de la derecha muestra los resultados de sensibilidad, especificidad y precisión obtenidos.
- 4) Bloque de tareas, *tasks*. Permite seleccionar mediante casillas de verificación las operaciones a realizar sobre la imagen, así como seleccionar el método de diagnóstico a utilizar mediante la lista desplegable.
- 5) La casilla de verificación *debug* permite especificar si se desea ver información adicional durante el procesamiento de la imagen, como por ejemplo representaciones intermedias de la imagen mediante figuras externas a la interfaz, o información de texto a través de la

consola de Matlab. En el modo de procesado en lote *debug* se desactiva automáticamente para no aumentar en exceso el uso de memoria y el tiempo de cálculo.

- 6) La casilla de verificación *use DB segmentation* permite especificar si se desea utilizar la máscara binaria de la segmentación manual proporcionada por la base de datos, o el resultado de la segmentación automática implementada.
- 7) La casilla de verificación *use annotation tool* permite especificar si se desea utilizar la herramienta de marcado manual para las características estructurales de puntos y glóbulos, *streaks* y áreas de regresión.
- 8) Bloque de diagnóstico. Contiene una tabla que se rellena con los datos de *ground truth* (columna de la izquierda) y los datos resultantes del procesado (columna de la derecha). El cuadro de texto de la izquierda muestra además la evaluación del diagnóstico de la lesión, siendo los valores posibles TP, FP, TN y FN.
- 9) Bloque de resultados: se utiliza para representar la imagen procesada junto a información gráfica adicional. Las casillas de verificación permiten activar y desactivar la visualización de capas adicionales, como pueden ser la segmentación de diferentes estructuras detectadas, el borde de la lesión o la información de asimetría.

Referencias

- [1] American Cancer Society, "Cancer Facts & Figures 2014," 2014.
- [2] World Health Organization, "How common is skin cancer?" [Online]. Available: <http://www.who.int/uv/faq/skincancer/en/index1.html>.
- [3] "¿Qué es el cáncer de piel tipo melanoma?" [Online]. Available: <http://www.cancer.org/espanol/cancer/cancerdepieltipomelanoma/guiadetallada/cancer-de-piel-tipo-melanoma-what-is-what-is-melanoma>. [Accessed: 02-Apr-2014].
- [4] Wikipedia, "Melanoma." [Online]. Available: <http://es.wikipedia.org/wiki/Melanoma>. [Accessed: 23-Jun-2014].
- [5] Wikipedia, "Melanina." [Online]. Available: <http://es.wikipedia.org/wiki/Melanina>. [Accessed: 22-Jun-2014].
- [6] Instituto Nacional del Cáncer de los Institutos Nacionales de la Salud de EE.UU., "Información sobre los estadios del melanoma." [Online]. Available: <http://www.cancer.gov/espanol/pdq/tratamiento/melanoma/HealthProfessional/page3>. [Accessed: 10-May-2014].
- [7] T. B. Fitzpatrick, "Soleil et Peau," *J. Médecine Esthétique*, no. 2, pp. 33–34, 1975.
- [8] I. N. del C. de los I. N. de la S. de EE.UU., "Lunares comunes, nevos displásicos y el riesgo de melanoma." [Online]. Available: <http://www.cancer.gov/espanol/recursos/hojas-informativas/riesgo-causas/lunares>. [Accessed: 12-Mar-2014].
- [9] A. Oakley, "Other algorithms for melanocytic lesions," 2008. [Online]. Available: <http://dermnetnz.org/doctors/dermoscopy-course/algorithms.html>. [Accessed: 27-Mar-2014].
- [10] F. Nachbar, W. Stolz, T. Merkle, A. B. Cognetta, T. Vogt, M. Landthaler, P. Bilek, O. Braun-Falco, and G. Plewig, "The ABCD rule of dermatoscopy," *J. Am. Acad. Dermatol.*, vol. 30, no. 4, pp. 551–559, Apr. 1994.
- [11] S. W. Menzies, C. Ingvar, K. A. Crotty, and W. H. McCarthy, "Frequency and morphologic characteristics of invasive melanomas lacking specific surface microscopic features.," *Arch. Dermatol.*, vol. 132, no. 10, pp. 1178–82, Oct. 1996.
- [12] J. S. Henning, S. W. Dusza, S. Q. Wang, A. a Marghoob, H. S. Rabinovitz, D. Polsky, and A. W. Kopf, "The CASH (color, architecture, symmetry, and homogeneity) algorithm for dermoscopy.," *J. Am. Acad. Dermatol.*, vol. 56, no. 1, pp. 45–52, Jan. 2007.

- [13] C. Rosendahl, "Dermatoscopy in routine practice," vol. 41, no. 7, pp. 482–487, 2012.
- [14] C. Rosendahl, A. Cameron, P. Tschandl, A. Bulinska, J.-Y. Gourhant, S. Minas, and H. Kittler, "CHAOS & CLUES: An Algorithm for the Diagnosis os Malignancy (any type) in Pigmented Skin Lessions by Dermatoscopy." .
- [15] R. C. González and R. E. Woods, *Tratamiento digital de imágenes*. Addison-Wesley Iberoamericana, S.A., Ediciones Díaz de Santos, S.A, 1996.
- [16] N. Otsu, "A Threshold Selection Method from Gray-Level Histograms," *IEE Trans. Syst. Man Cybern.*, vol. 9, no. 1, pp. 62–66, 1979.
- [17] R. O. Duda, P. E. Hart, and D. G. Stork, *Pattern Classification*, 2nd ed. 2000, p. 680.
- [18] E. Versi, "„Gold standard“ is an appropriate term.," *BMJ*, vol. 305, no. 6846, p. 187, Jul. 1992.
- [19] M. E. Celebi, G. Schaefer, and H. Iyatomi, "Objective evaluation of methods for border detection in dermoscopy images.," *Conf. Proc. IEEE Eng. Med. Biol. Soc.*, vol. 2008, pp. 3056–9, Jan. 2008.
- [20] G. Sethumadhavan and S. Sankaran, "Border Detection and Cancer Propagation on Spectral Bands of Malignant Melanoma Using Six Sigma Threshold," in *2009 Eighth IEEE/ACIS International Conference on Computer and Information Science*, 2009, pp. 586–592.
- [21] M. Messadi, H. Cherifi, and A. Bessaid, "Segmentation and ABCD rule extraction for skin tumors classification," vol. 9, no. March, pp. 21–34, 2014.
- [22] C. F. Ocampo Blandón, "Herramienta Soporte al Diagnóstico del Melanoma usando Imagenes Dermatoscópicas," 2011.
- [23] F. Peruch, F. Bogo, M. Bonazza, V.-M. Cappelleri, and E. Peserico, "Simpler, Faster, More Accurate Melanocytic Lesion Segmentation through MEDS.," *IEEE Trans. Biomed. Eng.*, no. c, pp. 1–9, Sep. 2013.
- [24] G. Di Leo, a. Paolillo, P. Sommella, and G. Fabbrocini, "Automatic Diagnosis of Melanoma: A Software System Based on the 7-Point Check-List," *2010 43rd Hawaii Int. Conf. Syst. Sci.*, pp. 1–10, 2010.
- [25] P. M. Ferreira, T. Mendonça, J. Rozeira, and P. Rocha, "An annotation tool for dermoscopic image segmentation," *Proc. 1st Int. Work. Vis. Interfaces Gr. Truth Collect. Comput. Vis. Appl. - VIGTA '12*, pp. 1–6, 2012.
- [26] W.-Y. Chang, A. Huang, C.-Y. Yang, C.-H. Lee, Y.-C. Chen, T.-Y. Wu, and G.-S. Chen, "Computer-aided diagnosis of skin lesions using conventional digital photography: a reliability and feasibility study.," *PLoS One*, vol. 8, no. 11, p. e76212, Jan. 2013.

- [27] R. Garnavi, M. Aldeen, and J. Bailey, "Computer-aided diagnosis of melanoma using border and wavelet-based texture analysis.," *IEEE Trans. Inf. Technol. Biomed.*, vol. 16, no. 6, pp. 1239–52, Nov. 2012.
- [28] G. K. Asunción Batugo, "Reconocimiento automático de melanomas mediante técnicas de visión por ordenador y reconocimiento de patrones," 2012.
- [29] P. Schmid, "Segmentation and symmetry measure for image analysis: application to digital dermatoscopy," vol. 2045, 1999.
- [30] E. E. Technion and T. Haifa, "Detecting Symmetry in Grey Level Images : The Global Optimization Approach Nahum Kiryati and Yossi Gofman."
- [31] A. Madooei, M. S. Drew, M. Sadeghi, and M. S. Atkins, "Automatic detection of blue-white veil by discrete colour matching in dermoscopy images.," *Med. Image Comput. Comput. Assist. Interv.*, vol. 16, no. Pt 3, pp. 453–60, Jan. 2013.
- [32] M. Sadeghi, M. Razmara, T. K. Lee, and M. S. Atkins, "A novel method for detection of pigment network in dermoscopic images using graphs.," *Comput. Med. Imaging Graph.*, vol. 35, no. 2, pp. 137–43, Mar. 2011.
- [33] J. Jaworek-korjakowska and R. Tadeusiewicz, "Assessment of dots and globules in dermoscopic color images as one of the 7-point check list criteria," pp. 1456–1460, 2013.
- [34] T. Mendonca, P. M. Ferreira, J. S. Marques, A. R. S. Marcal, and J. Rozeira, "PH(2) - A dermoscopic image database for research and benchmarking.," *Conf. Proc. IEEE Eng. Med. Biol. Soc.*, vol. 2013, pp. 5437–40, Jan. 2013.
- [35] P. Zaballos, C. Carrera, S. Puig, and J. Malvehy, "Criterios dermatoscópicos para el diagnóstico del melanoma," vol. 32, 2004.
- [36] T. Nagaoka, a Nakamura, Y. Kiyohara, and T. Sota, "Melanoma screening system using hyperspectral imager attached to imaging fiberscope.," *Conf. Proc. IEEE Eng. Med. Biol. Soc.*, vol. 2012, pp. 3728–31, Jan. 2012.